



*Escuela Técnica Superior de
Ingenieros de Caminos, Canales
y Puertos.*



UNIVERSIDAD DE CANTABRIA

Desarrollo de un hindcast híbrido de oleaje espectral para el atolón de Majuro (República de las Islas Marshall)

Trabajo realizado por:

Alba Ricondo Cueva

Dirigido:

Fernando J. Méndez Incera

Laura Cagigal Gil

Titulación:

**Máster Universitario
en Costas y Puertos**

Santander, octubre de 2019

TRABAJO FINAL DE MASTER

Desarrollo de un hindcast híbrido de oleaje espectral para el atolón de Majuro (República de Las Islas Marshall)

Autora: Alba Ricondo Cueva

Directores: Fernando J. Méndez Incera, Laura Cagigal Gil

Convocatoria: octubre 2019

RESUMEN

En pequeñas islas del Pacífico, donde la mayor parte de la superficie emergida apenas supera los 3 m de altitud, es esencial disponer de un hindcast de oleaje preciso que permita reducir su susceptibilidad a la inundación y mejore la adaptación al cambio climático. El objetivo de este trabajo es desarrollar una metodología que permita transferir la información del oleaje espectral de profundidades indefinidas a costa para el atolón de Majuro (República de las Islas Marshall). La metodología combina la creación de un input basado en la agregación de los sistemas de oleaje que llegan a Majuro, técnicas de selección y clasificación MDA (algoritmo de máxima disimilitud), downscaling dinámico con el modelo numérico SWAN y reconstrucción de las series en un punto cercano a costa mediante la técnica de interpolación RBF (Funciones de base radial).

La información del oleaje espectral proviene del hindcast de CSIRO de 40 años de datos 1979-2019 en el que se usó el modelo de oleaje WaveWatch III sobre una malla global de $0.4 \times 0.4^\circ$ con una serie de mallas anidadas en las regiones del Pacífico Occidental y Australia. Todas las mallas fueron forzadas con vientos CFSR (Climate Forecast System Reanalysis) horarios y de resolución espacial 0.3° .

La batimetría de la zona de estudio se ha obtenido a partir de la malla global GEBCO (General Bathymetric Chart of the Oceans), una malla con cobertura global en una cuadrícula de 15 arcosegundos de resolución. Los 450 m de resolución de la malla no son capaces de incluir los procesos de transformación del oleaje, por lo que se anida una segunda batimetría de mayor resolución para dicha zona. Esta segunda batimetría se ha obtenido a partir del modelo digital de elevación topo batimétrico de 5 m de resolución desarrollada por el USGS (United States Geological Survey).

La definición del input se realiza a partir de las particiones del espectro direccional completo, diferenciando entre sea y diferentes swells por el método watershed (Hanson and Philips, 2001) y parametrizando cada sistema en sus variables representativas. Para el caso de mar de viento se obtendrán los siguientes parámetros: Altura de ola significativa (H_s), periodo pico (T_p), dirección media (θ_m), dispersión direccional (σ), el parámetro γ de Jonswap obtenido mediante la relación entre periodo pico y periodo medio y las variables asociadas a la velocidad y dirección del viento (W_{spd} , W_{dir}). En el caso de mar de fondo o swells, los parámetros serán los mismos a excepción de las variables asociadas al viento. De forma paralela, y para su comparación con el caso del uso de particiones, la metodología se aplicará además para un input basado únicamente en los parámetros agregados del espectro (H_s , T_p , θ_m).

Previo a la clasificación MDA, se ha realizado un análisis de sensibilidad del periodo de pico T_p , dispersión angular σ , gamma de Jonswap γ y nivel del mar, observando el aumento significativo de la altura de ola propagada cuando aumenta el nivel del mar o se reduce el periodo de pico.

Modificando la forma del espectro hacia un espectro tipo swell disminuyendo la dispersión angular o aumentando el gamma de Jonswap también se aumenta la altura de ola al concentrar la energía en menos frecuencias.

El alto coste computacional que supondría propagar las distintas particiones a lo largo de un periodo de 40 años hace necesario emplear herramientas estadísticas que permitan reducir el conjunto de datos a un número de casos representativos para realizar un downscaling híbrido. Se emplea para ello el algoritmo MDA para la selección de un subconjunto de 500 casos en cada conjunto de datos (parámetros agregados, seas y swells). Los casos previamente seleccionados se propagan con el modelo numérico de tercera generación SWAN. Para conocer la propagación de los restantes casos se usan una técnica de interpolación no lineal basada en RBF.

Por último, la validación de las series reconstruidas frente a datos de boya muestra la capacidad del downscaling híbrido para mejorar el conocimiento del clima marítimo en pequeñas islas. A partir de los datos de una boya situada al este del atolón se ha podido comparar el resultado de la altura de ola significativa reconstruida mediante las particiones del espectro y mediante parámetros agregados. Los parámetros agregados no son capaces de recoger toda la energía del espectro al estar ésta influenciada por los vientos del este que encuentran en su propagación el atolón de Arno al este de Majuro. El método de las particiones, por el contrario, proporciona una validación satisfactoria de la altura de ola significativa, recogiendo con mayor exactitud la energía de todas las direcciones de las familias de oleaje que llegan a Majuro.

Palabras clave: Hindcast, Downscaling híbrido, Particiones espectrales, Espectro direccional, Sistemas de oleaje espectrales, Clima marítimo, Mar de viento, Mar de fondo

On the development of a hybrid spectral wave hindcast for Majuro Atoll (Republic of Marshall Islands)

Author: Alba Ricondo Cueva

Directors: Fernando J. Méndez Incera, Laura Cagigal Gil

Call: October 2019

ABSTRACT

In small Pacific islands, where most of the surface area is just over 3 m above sea level, it is essential to have an accurate wave hindcast to reduce susceptibility to flooding and improve adaptation to climate change. The aim of this work is to develop a methodology to transfer spectral wave information from deep water to the coast for Majuro Atoll (Marshall Islands Republics). The methodology combines the creation of an input based on the aggregation of the wave systems arriving at Majuro, MDA (maximum dissimilarity algorithm) selection and classification techniques, dynamic downscaling with the SWAN numerical model and reconstruction of the series at a particular point close to the coast using the RBF (radial base functions) interpolation technique.

The spectral wave information comes from the 40 year hindcast (1979-2019) of CSIRO, in which the WaveWatch III wave model was used on a $0.4 \times 0.4^\circ$ global mesh with a series of nested meshes in the Western Pacific and Australian regions. All the meshes were forced with CFSR (Climate Forecast System Reanalysis) hourly winds with 0.3° of spatial resolution.

The bathymetry of the study area has been obtained from the global mesh GEBCO (General Bathymetric Chart of the Oceans), a mesh with global coverage in a grid of 15 arcseconds of resolution. The 450 m resolution of the mesh is not capable of including the processes of wave transformation, so a second bathymetry of higher resolution is nested for this area. This second bathymetry has been obtained from the digital model of topo-bathymetric elevation of 5 m of resolution developed by the USGS (United States Geological Survey).

The definition of the input is made from the partitions of the full directional spectrum, differentiating between sea and different swells by the watershed method (Hanson and Philips, 2001) and parameterizing each system in its representative variables. In the case of wind sea, the following parameters will be obtained: Significant wave height (H_s), peak period (T_p), mean direction (θ_m), directional dispersion (σ), the Jonswap parameter (γ) obtained through the relationship between peak period and mean period and the variables associated with wind speed and direction (W_{spd} , W_{dir}). In the case of swells, the parameters will be the same except for the variables associated with the wind. In parallel, and for comparison with the case of the use of partitions, the methodology will also be applied for an input based only on the aggregated parameters of the spectrum (H_s , T_p , θ_m).

Prior to the MDA classification, a sensitivity analysis of the peak period T_p , angular dispersion σ , Jonswap gamma (γ) and sea level has been performed, observing the significant increase in the propagated wave height when sea level rises or the peak period falls. Modifying the shape of the spectrum towards a swell spectrum by decreasing the angular dispersion or increasing the Jonswap gamma also increases the wave height by concentrating the energy in fewer frequencies.

The high computational cost of propagating the different partitions over a period of 40 years requires statistical tools to reduce the data set to a representative number of cases to perform hybrid downscaling. The MDA algorithm is used to select a subset of 500 cases in each data set (aggregated parameters, seas and swells). The previously selected cases are propagated with the third generation SWAN numerical model. In order to know the propagation of the remaining cases, a non-linear interpolation technique based on RBF is used.

Finally, the validation of the reconstructed series against buoy data shows the ability of hybrid downscaling to improve knowledge of the maritime climate on small islands. From the data of a buoy located east of the atoll, it has been possible to compare the result of significant wave height reconstructed using spectrum partitions and aggregated parameters. The aggregated parameters are not able to collect all the energy of the spectrum because it is influenced by the east winds that find in its propagation the atoll of Arno east of Majuro. The partition method, on the contrary, provides a satisfactory validation of the significant wave height, collecting more accurately the energy from all directions of the families of waves that arrive at Majuro.

Keywords

Hindcast, hybrid downscaling, Spectral partitioning, Directional wave spectra, Spectral wave systems, Spectral wave climate, Wind sea, Swell

ÍNDICE

1	INTRODUCCIÓN	7
1.1	Motivación del estudio	7
1.2	Objetivos	7
2	METODOLOGÍA	8
3	DATOS	8
3.1	Información espectral	8
3.2	Topo-batimetría	9
3.3	Boya	10
4	DESCRIPCIÓN DE LA ZONA DE ESTUDIO	12
4.1	Localización	12
4.2	Dinámicas marinas	12
5	PARTICIONES DEL ESPECTRO DIRECCIONAL	13
6	MODELO NUMÉRICO DE PROPAGACIÓN (SWAN)	18
6.1	Introducción	18
6.2	Input	19
7	ANÁLISIS DE SENSIBILIDAD	21
8	OLEAJE EN LA LAGUNA INTERIOR	22
9	ALGORÍTMO DE CLASIFICACIÓN DE MÁXIMA DISSIMILITUD (MDA)	24
10	RESULTADOS DE LA PROPAGACIÓN NUMÉRICA	27
11	RECONSTRUCCIÓN (RBF)	31
12	VALIDACIÓN	34
13	ESTUDIO DEL CLIMA MARÍTIMO	39
14	CONCLUSIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN	43
14.1	Conclusiones	43
14.2	Hipótesis y limitaciones	44
14.3	Futuras líneas de investigación	44
15	REFERENCIAS	45
16	ANEJO1. CÓDIGOS EN JUPYTER NOTEBOOK	46

1 INTRODUCCIÓN

1.1 Motivación del estudio

La superficie libre del mar en un punto del océano es el resultado de la suma de varios sistemas de oleaje, formados generalmente por un mar de viento local y varios sistemas de swells generados por tormentas lejanas. Durante estas tormentas, fuertes vientos soplando sobre una determinada región generan swells que se propagan a veces miles de kilómetros desde la fuente de generación. Cuando estos swells llegan a costa, se generan ondas infragravitatorias que dan lugar a olas individuales con gran potencial de generar eventos de inundación.

En diciembre de 2008, varias islas del Pacífico occidental sufrían el impacto severo de la inundación durante días. Estos eventos no estaban asociados a ciclones tropicales o a grandes mareas astronómicas, sino que la principal causa de inundación era la llegada de swells originados en tormentas lejanas (Hoeke et al., 2013).

La variabilidad interanual de la región y el rápido aumento del nivel del mar, hace que en pequeñas islas del Pacífico donde la mayor parte del área emergida está a menos de 3 metros de altitud, sea esencial disponer de un hindcast de oleaje que permita realizar predicciones precisas y puedan reducir así su susceptibilidad a la inundación.

Este estudio se desarrolla en Majuro, un atolón de las islas Marshall al que pueden llegar más de 10 swells generados en el norte y sur del Pacífico. En el estudio desarrollado por (Ford et al., 2018) se realiza una recopilación de los eventos de inundación en Majuro desde 1979 a 2015 encontrando varios modos de inundación costera y del lago interior.

Tradicionalmente en ingeniería de costas, se agrega la información del espectro direccional completo en parámetros únicos como la altura de ola significativa (H_s), el período de pico (T_p) y la dirección media (θ_m). Sin embargo, esto supone perder una cantidad significativa de detalles relacionados con la propagación de la energía y su llegada a costa, donde el clima marítimo es sensible a pequeñas variaciones del espectro direccional.

Por este motivo, se propone el desarrollo de un hindcast híbrido a partir de un oleaje multimodal, que refleje correctamente el estado de mar, estudiando el comportamiento de cada partición o sistema del espectro direccional completo y que permita caracterizar el clima marítimo en cualquier punto del atolón de Majuro.

1.2 Objetivos

Se plantean los siguientes objetivos:

- (1) Desarrollar una metodología que describa adecuadamente el clima marítimo en la costa de Majuro considerando el espectro direccional completo
- (2) Analizar la sensibilidad de los diferentes parámetros que definen el espectro direccional en la propagación a costa
- (3) Comparar las diferencias entre la propagación del oleaje espectral a través de parámetros agregados y la propagación mediante el uso de particiones

2 METODOLOGÍA

Se define un sistema híbrido estadístico-dinámico para evaluar el clima marítimo en pequeñas islas del Pacífico. Esta metodología híbrida es aplicable en costas donde la propagación del clima marítimo pueda asimilarse como espectral lineal y combina lo siguiente:

- (1) Definición del input de un modelo numérico basado en la agregación de los diferentes sistemas de oleaje que caracterizan el espectro multimodal en Majuro denominado (“Superespectro”)
- (2) Obtención de las particiones del espectro direccional completo para la identificación de los sistemas de mar de viento (sea) y de mar de fondo (swell). Parametrización de cada sistema de swell ($H_s, T_p, \theta_m, \sigma, \gamma$) y de sea ($H_s, T_p, \theta_m, \sigma, \gamma, W_{spd}, W_{dir}$), donde H_s es la altura de ola significativa, T_p el periodo de pico, θ_m la dirección media de propagación, σ la dispersión direccional, γ el factor de apuntamiento gamma de Jonswap, W_{spd} y W_{dir} , la velocidad y dirección del viento a 10 m de la superficie del mar.
- (3) Selección de N casos representativos mediante el algoritmo de clasificación de Máxima Disimilitud (MDA)
- (4) Propagación de los casos previamente seleccionados con un modelo numérico de propagación de oleaje (SWAN)
- (5) Reconstrucción de la serie de oleaje en un punto cercano a la costa mediante funciones de base radial (RBF)
- (6) Validación de la metodología propuesta con datos de boya
- (7) Análisis del clima marítimo

El conjunto de pequeñas islas que forman las Islas Marshall son islas volcánicas con una plataforma continental muy estrecha donde podemos asumir que los procesos de transformación de oleaje no lineales en aguas someras son mínimos y por tanto aplicar teoría lineal. Aplicando esta teoría sabemos que la propagación de un estado de mar compuesto por un sea ($H_{s1}, T_{p1}, \theta_{m1}, \sigma_1, \gamma_1$) y dos swells ($H_{s2}, T_{p2}, \theta_{m2}, \sigma_2, \gamma_2$), ($H_{s3}, T_{p3}, \theta_{m3}, \sigma_3, \gamma_3$) será la suma lineal de los espectros propagados $S_p(f, \theta) = S_1(f, \theta) + S_2(f, \theta) + S_3(f, \theta)$ y que el espectro propagado será el original afectado por un coeficiente de propagación función de la frecuencia y dirección de cada paquete de energía $S_p(f, \theta) d\theta = S_0(f, \theta_0) |k_f(f, \theta_0)|^2 d\theta_0$. De forma paralela, se aplicará el mismo downscaling híbrido para un input basado en los parámetros agregados del espectro, para de esta forma poder comparar la bondad del método propuesto.

3 DATOS

3.1 Información espectral

Las condiciones de contorno de oleaje para las posteriores propagaciones de SWAN, provienen del hindcast de oleaje desarrollado en Australia por CSIRO (Commonwealth Scientific and Industrial Research Organisation) bajo el nombre CAWCR Wave Hindcast 1979-2019. En este hindcast se usó el modelo de oleaje WaveWatch III v4.08 en una malla global de $0.4 \times 0.4^\circ$ con una serie de mallas anidadas de 10 arco-minutos (~ 18 km) hasta 4 arco-minutos (~ 7 km) en las regiones del Pacífico Occidental y Australia (Figura 1). Todas las mallas fueron forzadas con vientos de CFSR (Climate Forecast System Reanalysis) horarios y de resolución espacial 0.3° . También se tuvieron en cuenta las concentraciones de hielo horarios de la base de datos del CFSR.




Figura 1. Red de puntos del hindcast CAWCR Wave Hindcast 1979-2019 de CSIRO en las regiones del Pacífico Occidental y Australia con resolución de 7 km

El output del modelo se obtuvo en 3683 puntos, así como en los nodos de la malla de 0.4° de resolución. La información espectral está discretizada en 29 frecuencias desde 0.038 Hz a 0.5 Hz y 24 direcciones cada 15° . Esta red de puntos del CSIRO en el Pacífico proporciona información del oleaje de 3 formas distintas, (1) a partir del espectro direccional completo $S_{\eta\eta}(f, \theta)$, (2) con los parámetros agregados en cada punto H_s, T_p, θ_m y (3) con los parámetros desagregados o particiones de las distintas familias que llegan a cada punto de la malla. Para este estudio se ha obtenido el espectro direccional completo en 6 puntos alrededor de los atolones de Majuro y Arno.

3.2 Topo-batimetría

La batimetría de la zona de estudio se ha obtenido a partir de la malla global GEBCO (General Bathymetric Chart of the Oceans) desarrollada en el proyecto Nippon Foundation-GEBCO Seabed 2030. Este proyecto tiene como objetivo reunir todos los datos batimétricos disponibles para generar un mapa definitivo del fondo oceánico mundial. El último producto es GEBCO_2019, una malla con cobertura global en una cuadrícula de 15 arcosegundos de resolución que abarca $89^\circ 59' 52.5''N, 179^\circ 59' 52.5''O$ a $89^\circ 59' 52.5''S, 179^\circ 59' 52.5''E$ y está libre para su descarga en formato NetCDF. Para esta primera malla general se obtuvo la información batimétrica entre las coordenadas de longitud $[170.88, 171.93]^\circ$ y latitud $[6.8021, 7.3271]^\circ$.

El atolón de Majuro tiene una longitud aproximada de 40 km y la resolución de la batimetría GEBCO sobre la zona de estudio es de 420 m. Esta resolución no es capaz de definir correctamente las 64 islas que forman el atolón, ni los procesos de transformación que sufriría el oleaje al alcanzarlas. Por este motivo, se ha propuesto anidar una segunda batimetría de mayor resolución para la zona de estudio.

Esta segunda batimetría se ha obtenido a partir del modelo digital de elevación topo batimétrico de 5 m de resolución desarrollada por el USGS (United States Geological Survey) (Figura 2). Las

elevaciones se ajustan al nivel medio del mar local y la información incluye el atolón de Majuro y extiende el este de la isla a mayor profundidad offshore.

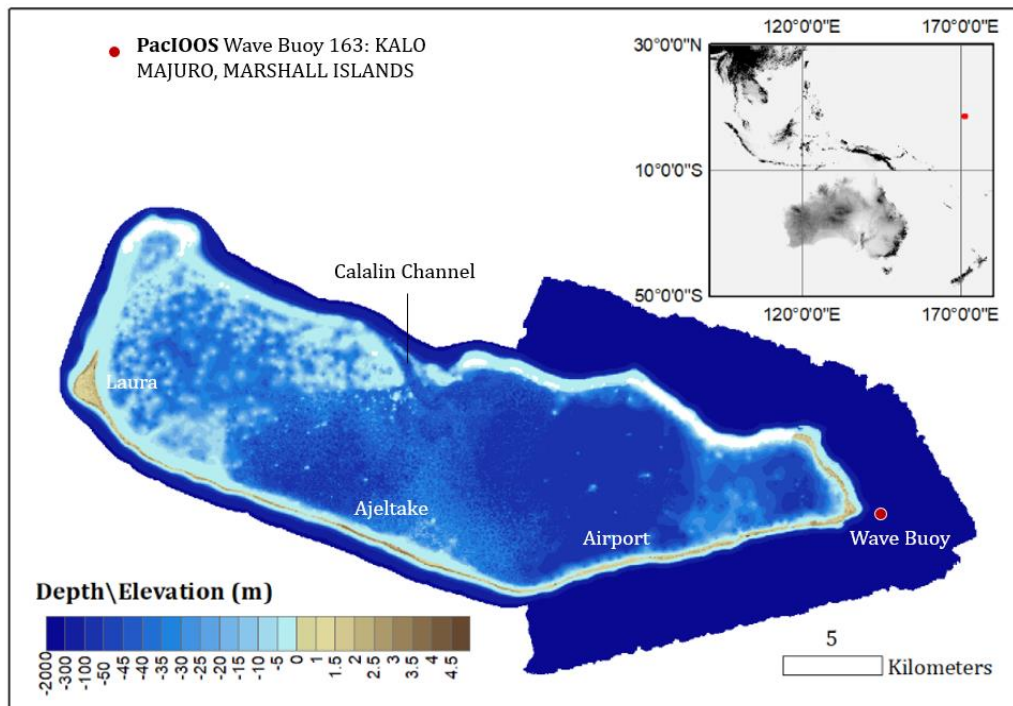


Figura 2. Batimetría de detalle USGS (5 m) y localización en el Pacífico norte

3.3 Boya

La metodología propuesta finalmente será validada a partir de los datos de una boya direccional cercana a la costa de Majuro. PacIOOS (The Pacific Islands Ocean Observing System) es una asociación de proveedores y usuarios de datos del conjunto de las Islas del Pacífico que trabajan juntos para elaborar, difundir, evaluar y aplicar productos de datos e información oceanográfica. En la isla de Majuro, disponen de una boya con coordenadas $7^{\circ} 5.01'N$, $171^{\circ}23.51'E$ a 0.9 km de la costa este a una profundidad de 450 m (Figura 2). La información disponible consiste en datos de H_s , T_p y θ_m dados cada media hora en formato de la zona horaria MHT (Marshall Islands UTC+12). El registro de datos de la boya tiene información desde el 2010 al 2019 de forma discontinua (Figura 3). Existen varios picos de altura de ola significativa, con valores inusualmente grandes de 4 – 4.5 m que puedan estar asociados a la llegada o al residuo de algún ciclón tropical. La serie muestra la variabilidad intra-anual de inviernos con oleajes más energético y por tanto más altura de ola y verano con altura significativa media de 0.7 m. Por la localización de la boya a 0.9 km de la costa y en profundidades indefinidas, ésta siempre mide energía con mínimo de 0.5 m de altura de ola significativa.




Figura 3. Serie temporal de la altura de ola significativa proporcionada por la boyo

En la Figura 4 se representa la altura de ola y periodo de pico asociado a la dirección de oleaje. Alturas de ola máximas tienen una dirección de 30° generados por los vientos alisios que soplan del NE al SO. Los periodos máximos llegan como swells de 20 s de periodo máximo generados a grandes distancias en el norte y sur del Pacífico.




Figura 4. Periodo de pico y altura de ola significativa proporcionada por la boyo

4 DESCRIPCIÓN DE LA ZONA DE ESTUDIO

4.1 Localización

Majuro es la capital de la República de las Islas Marshall, un país insular ubicado en la región de Micronesia, en el océano Pacífico. Formado por 64 islas, Majuro es un atolón de 9.7 km² de superficie terrestre con una laguna en su interior de 295 km² en el que habitan 28000 habitantes (2012) (Ford et al., 2018) (Figura 5).

Los atolones se definen como islas coralinas oceánicas, generalmente con forma de anillo que se forman cuando un arrecife de coral crece alrededor de una isla volcánica. El arrecife poco profundo queda expuesto en bajamar y sumergido en pleamar, ofreciendo una barrera de protección frente a la llegada del oleaje que disipa la energía por rotura, fricción y turbulencia. En la propagación del oleaje a costa, se generan un set-up o sobre elevación de la lámina de agua sobre el arrecife de ~ 0.2 veces la altura de ola en rotura (Ford et al., 2018).




Figura 5. Localización del atolón de Majuro en las Islas Marshall (a) y vista de la zona este donde se concentra la población (b). Fuente: (Ford et al., 2018)

4.2 Dinámicas marinas

La marea en Majuro es semidiurna, con un rango en mareas vivas de 1.6 metros e importantes diferencias entre pleamar y bajamar. Las mayores mareas vivas del año, llamadas “King tides” ocurren entre los meses de enero y marzo. El patrón de oscilación El Niño Southern Oscillation (ENSO) tiene un papel importante en las fluctuaciones interanuales del nivel del mar en la región, experimentando grandes anomalías durante la fase de La Niña (Ford et al., 2018).

El oleaje dominante proviene de las direcciones norte y noreste, con una altura media en el cuadrante de 1.6 m. En el trabajo de (Ford et al., 2018) se recopilan los eventos de inundación en Majuro de los últimos 36 años definiendo 5 posibles formas de inundación, (1) llegada de swells generados en el norte y sur del Pacífico, (2) tormentas tropicales y tifones, y los modos de inundación del lago interior (3) niveles de mar elevados durante la fase ENSO de La Niña, (4) penetración de la llegada de swells al lago y (5) oleaje generado por viento.

El conocimiento local de los swells del Pacífico ha permitido la navegación de los antiguos habitantes de las islas Marshall entre sus islas. Los navegantes sentían remotamente la tierra al

detectar como las islas interrumpían la propagación de los swells y utilizaban estos patrones del oleaje para el establecimiento del curso, la orientación, la estimación de progreso y la detección remota de tierra (Genz, et al., 2009) (Figura 6). En las islas Marshall, los trenes de onda cruzados se extienden por decenas de kilómetros al abrigo de las islas, lo que puede entenderse como la refracción del oleaje del este. Los navegantes identificaron una superposición de olas incidentes con ondas reflejadas hasta 40 km aguas arriba de las islas. Estas ondas reflejadas eran demasiado débiles para ser detectadas por las boyas, pero se conceptualizan de manera similar dentro de los marcos indígenas y científicos.



Figura 6. El capitán korent Joel, uno de los últimos navegantes tradicionales de las Islas Marshall, explica los conceptos del oleaje mediante herramientas indígenas y demuestra como detentaban los patrones de oleaje sintiendo el movimiento que generan sobre una canoa de vela con balancín. Fuente: (Genz, et al., 2009)

Sumado a los distintos modos de inundación, la región está experimentando una rápida subida del nivel medio del mar. Majuro cuenta con un registro de nivel del mar desde 1969, separado en un periodo entre octubre de 1969 y diciembre de 1999 recogido por el Centro de Nivel del Mar de la Universidad de Hawaii (UHSLC) y por la Australian National Tidal Facility desde junio de 1993 hasta la actualidad. El registro combinado de mareógrafos presenta una tendencia de ascenso del nivel del mar de $3,3 \pm 0,6$ mm (Ford et al., 2018).

5 PARTICIONES DEL ESPECTRO DIRECCIONAL

La transformación del oleaje desde un punto en aguas indefinidas con espectro multimodal a costa no resulta sencilla en zonas con una batimetría y orientación complicada. Por este motivo, se propone evitar el uso de los parámetros agregados H_s, T_p, θ_m y discretizar el espectro direccional del oleaje en familias procedentes del mismo área de generación parametrizadas según $H_s, T_p, \theta_m, \sigma, \gamma$.

El input del modelo numérico de propagación se ha definido como un “Superespectro” basado en la confluencia de llegada de swells al atolón de Majuro. Este Superespectro agrega los estados de

mar multimodales de los 6 puntos del hindcast de CSIRO en un solo punto espectral representativo de la zona (Figura 7). De esta forma, el input recoge la energía que se propaga a Majuro desde cualquier dirección durante los 40 años de datos (1979-01-01 - 2019-02-01). Los sectores correspondientes a cada punto CSIRO son [330, 30], [30, 90], [90, 150], [150, 210], [210, 270], [270, 330].

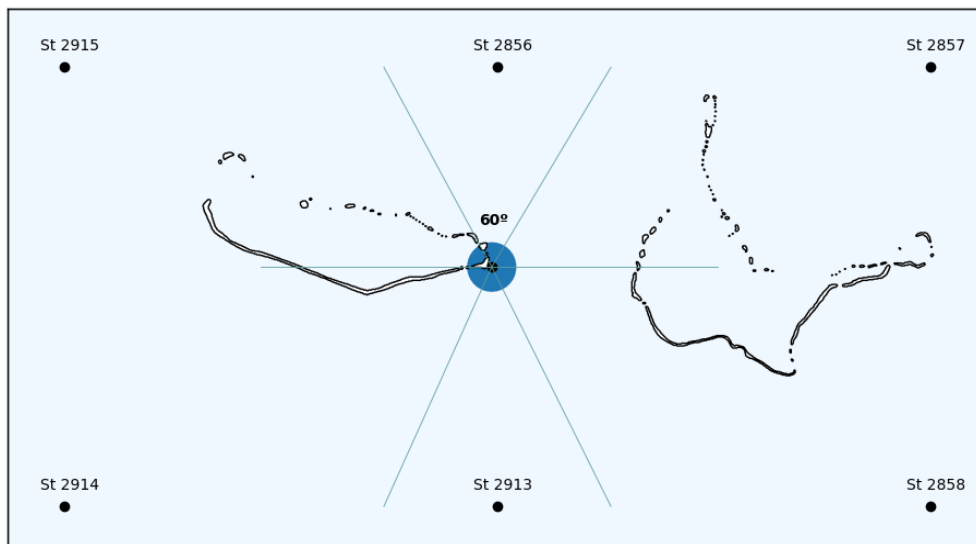


Figura 7. Esquema de las 6 estaciones de CSIRO y Superspectro

Los vientos NCEP CFSR con los que se forzó el hindcast de CSIRO, son también el input del Superspectro. Dada la resolución de esta base de datos, las series de velocidad y dirección del viento para las 6 estaciones tienen valores similares, por lo que se ha tomado como representativo de la zona el valor de viento medio.

Para identificar la estructura de los diferentes sistemas de oleaje presentes en un mismo instante, se realiza una división espectral. En este trabajo, desarrollado en el entorno de programación Python, cuyos códigos se pueden encontrar en el Anejo 1 de este trabajo, se ha hecho uso de la librería Wavespectra desarrollada en el mismo entorno por MetOcean Solutions y pública en GitHub (<https://github.com/metocean/wavespectra>). Wavespectra permite trabajar con grandes series de datos multidimensionales, realizando las integrales comunes de componentes como altura de ola, periodo y dirección, así como las particiones del espectro mediante diferentes métodos. El código está preparado para manejar la información espectral del output de modelos como WAVEWATCH III y SWAN (Simulating Waves Nearshore) y de ficheros comunes como netcdf.

En este trabajo, se han realizado las particiones mediante el método Watershed propuesto por (Hanson and Philips, 2001) e incluido en Wavespectra. Este método diferencia mar de viento y mar de fondo buscando los mínimos topográficos, identificando el mar de viento mediante un criterio de factor de edad del oleaje.

Las particiones del espectro permiten dividir la energía total en familias, cada una de ellas caracterizada por una serie de parámetros estadísticos. (Hanson and Philips, 2001) definen 5 pasos en el método de las particiones basándose en las ideas de Hasselmann et al. (1994):

- El primer paso consiste en dividir la matriz $S(f, \theta)$ siguiendo las pendientes ascendentes del espectro. De este modo, las particiones se dividen por los valles o mínimos

topográficos y es posible calcular para cada subespectro la energía total, la frecuencia pico f_p , la dirección pico θ_p y la energía pico $S(f_p, \theta_p)$.

- El siguiente paso es determinar cuál de las particiones ya definidas ha sido generada por viento local. Para ello se sigue un criterio de edad de oleaje que define una parábola sobre la matriz $S(f, \theta)$ de modo que la energía que se encuentre dentro de la parábola definida se considera mar de viento (Figura 8):

$$c_p \leq (1.5)U_{10} \cdot \cos\delta$$

siendo c_p la fase de la velocidad del viento, U_{10} la velocidad del viento a 10 m sobre la superficie del mar y δ el ángulo entre el viento y el mar de viento.




Figura 8. Criterio de edad para identificar el mar de viento según la parábola definida. Fuente: (Hanson and Philips, 2001)

Para evitar que dos picos del espectro muy próximos y generados en la misma región se consideren dos sistemas de swells distintos, se aplica un factor de umbral de distancias entre picos. De igual manera, existe un umbral de energía por debajo del cual el sistema no se considera partición.

A la partición de mar de viento se le asigna el número 0, mientras el resto de las particiones, consideradas swells o mar de fondo están numeradas según energía creciente (siendo la partición 1 la de mayor energía).

- Por último, se calculan todos los parámetros estadísticos de las particiones ya definidas. Mediante Wavespectra se obtienen las componentes de altura de ola significativa, periodo medio, periodo de pico, dirección de propagación y dispersión direccional. Para definir de forma correcta la forma del espectro, se ha añadido el factor de apuntamiento gamma del espectro Jonswap definido a partir del periodo medio y periodo pico de la siguiente forma:

$$\frac{T_p}{T_{m02}} = a \cdot \gamma^b$$

donde $a = 1.411$ y $b = -0.07972$

$$T_{m02} = 2\pi \cdot \sqrt{\frac{m_0}{m_2}}$$

$$T_{m02} = \sqrt{\frac{\iint S(f, \theta) \cdot df \cdot d\theta}{\iint f^2 \cdot S(f, \theta) \cdot df \cdot d\theta}}$$

$$H_{m0} = 4.004 \cdot \sqrt{\iint S(f, \theta) \cdot df \cdot d\theta}$$

A partir de un análisis previo del oleaje y el viento de CSIRO, se han podido determinar los parámetros de ajuste de Wavespectra. De este modo, se ha considerado un número máximo de swells de 5, altura de ola mínima de 0.001 m y umbral de viento próximo a 0. Con este umbral de viento nos aseguramos de que siempre que existe energía en la dirección del viento, la partición asociada es considerada como un sea. En la Figura 9 se muestran las distintas particiones del espectro horario en el periodo de 1980-01-02 00:00:00.00 a 1980-02-25 03:00:00.00.




Figura 9. Serie temporal de las variables H_s , T_p , θ_m , σ , $\log(\gamma)$ para la partición de mar de viento (partición 0) y mar de fondo o swells (1, 2, 3, 4, 5)

Los vientos alisios soplan de manera relativamente constante del NE en el hemisferio norte. En Majuro, el mar de viento que generan los alisios es la partición más energética con direcciones entre 30 y 50°. Al ser un sea, la energía se propaga en un mayor rango de frecuencias y direcciones por lo que la dispersión direccional es grande y el factor de apuntamiento de Jonswap es pequeño.

El espectro de Jonswap (Hasselman et al., 1973) define gammas en un rango general de 1 (sea) a 20 (swell). Cuando no se tiene información del espectro, se toma un valor por defecto de $\gamma = 3.3$ (valor que obtuvo en el mar de Japón). A Majuro llegan swells generados en el norte y sur del Pacífico, propagándose la energía muy concentrada en pocas frecuencias. Los puntos espectrales

del CSIRO tienen información de la energía en 29 frecuencias. Por este motivo, Wavespectra considera los swells de mayor periodo prácticamente como ondas monocromáticas, con toda la energía en una sola banda de frecuencias, parametrizando su gamma con valores máximos de hasta 200 y dispersiones frecuenciales casi nulas. Al ser γ un parámetro con una variabilidad exponencial muy grande, en adelante se utilizará $\log(\gamma)$.

A partir del análisis de los parámetros asociados a cada partición, se pueden calcular las áreas de generación de las familias de swells. (Portilla et al., 2012) utiliza la relación de dispersión en aguas profundas para relacionar la frecuencia del oleaje con su tiempo de llegada de manera lineal. El periodo de pico de la Figura 10, muestra un claro patrón de periodos descendentes en intervalos de tiempo. A su vez, en este mismo intervalo, la altura de ola asociada es creciente hasta un máximo donde comienza a decaer. Este comportamiento es el asociado a un swell llegando a costa. Por la relación de dispersión, periodos mayores viajan con mayor celeridad llegando primero a costa. Si se estudia la similitud entre los parámetros de las series se pueden obtener las parametrizaciones de cada sistema de oleaje en el tiempo.

En la Figura 10 se presentan tanto el espectro completo como los espectros direccionales de cada partición para el instante 1980-01-16 14:00. Se representa la raíz cuadrada de la varianza de densidad espectral direccional (efth) para poder comparar energías entre el mar de viento del E – NE y los swells menos energéticos de las demás direcciones.

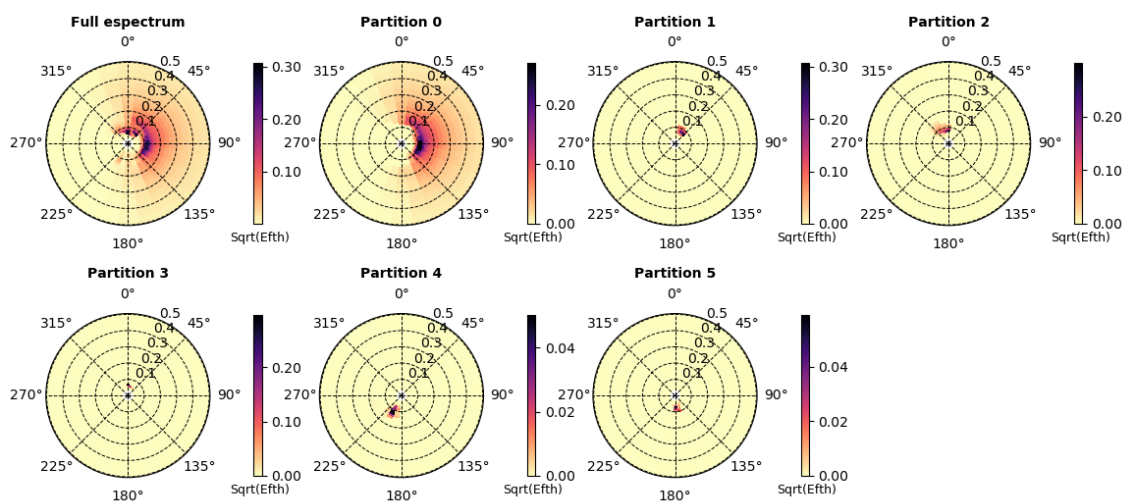


Figura 10. Espectros direccionales de las particiones de mar de viento y mar de fondo y el espectro direccional completo en el tiempo 1980-01-16 14:00

Por último, en la Figura 11 se compara la información espectral agregada con la información “unimodal” de cada partición a partir de la probabilidad de ocurrencia del pico del espectro en el espacio frecuencia-dirección (Portilla et al., 2015). Este gráfico de densidad espectral muestra la probabilidad de que un determinado sistema de oleaje provenga de una cierta dirección con una determinada frecuencia, y además aporta información de las posibles áreas de generación de los sistemas de oleaje.

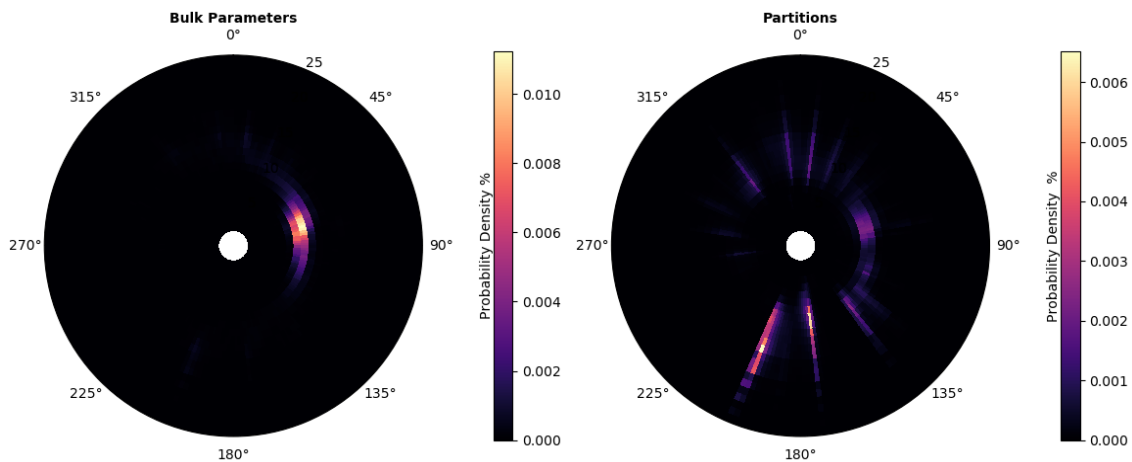


Figura 11. Densidad de probabilidad de ocurrencia del pico del espectro considerando parámetros agregados y considerando particiones

Considerando el clima marítimo dado por los parámetros agregados de cada estado de mar, en Majuro todo el oleaje tiene dirección este. Sin embargo, analizando la probabilidad de ocurrencia de cada división espectral se observa que el oleaje más probable, aun siendo menos energético, viene del sur. Esto ocurre cuando al agregar la energía de las diferentes particiones, la media hace perder información de las celdas de menor energía. El objetivo de este trabajo es desarrollar una metodología que incluya la importancia de los estados de mar menos energéticos al mismo tiempo que los dominantes del noreste.

6 MODELO NUMÉRICO DE PROPAGACIÓN (SWAN)

6.1 Introducción

En un punto del océano situado en profundidades indefinidas, la propagación de las ondas generadas por viento no se ve afectada por la batimetría. Es a medida que el oleaje se propaga a costa cuando este comienza a sufrir una serie de procesos de transformación y disipación de la energía.

Cuando el tren de onda se aproxima a la costa, al disminuir la profundidad, aumenta generalmente la altura de ola por asomeramiento, disminuyendo la longitud de onda por conservación del flujo de energía. Si el tren de ondas se propaga incidiendo oblicuamente sobre la costa y encuentra un cambio de profundidad, se produce el giro del frente por cambios en la velocidad de propagación (la parte del frente en aguas someras viaja a menor celeridad). Este proceso, llamado refracción, también ocurre cuando el frente de ondas se encuentra con una corriente. Por otro lado, si las ondas se encuentran en su propagación con una estructura o cuando pronunciados efectos de la refracción conducen a singularidades en la amplitud de la onda, se produce una cesión lateral de energía llamada difracción. Sobre pendientes pronunciadas, puede darse reflexión de parte de la energía incidente y disipación por rotura por fondo o peralte.

Los modelos numéricos simulan los procesos de transformación del oleaje en su propagación hacia costa. Existen diferentes modelos de oleaje dependiendo de las ecuaciones matemáticas que resuelven y que suponen diferentes limitaciones en los procesos que pueden modelar.

Principalmente se pueden distinguir dos tipos de modelos, por un lado, los que resuelven la fase de la onda, basados en ecuaciones de balance de masa y conservación del momento, integradas en vertical y dependientes del tiempo y, por otro lado, los modelos de fase promediada basados en la ecuación de balance de energía espectral. Los modelos de resolución de la fase requieren de 10 a 100 pasos de tiempo para cada periodo de oleaje, por lo que su aplicación se limita a áreas relativamente pequeñas (1-10 km), mientras que los modelos promediados en fase pueden aplicarse en regiones mucho más extensas (Losada y Liu, 2002).

En este trabajo, se emplea el modelo numérico espectral de propagación de oleaje SWAN (Booij et al., 1999). El objetivo es transferir la información del oleaje de aguas profundas a costa, aumentando la resolución espacial, de modo que se incluyan los procesos de transformación del oleaje (downscaling dinámico). SWAN es un modelo numérico de propagación de oleaje de tercera generación desarrollado por la Universidad de Tecnología de Delft (Delft University of Technology) para obtener estimaciones realistas de los parámetros de oleaje en zonas costeras, lagos y estuarios a partir de condiciones de viento, fondo y corrientes. Para incluir el detalle de la energía que se genera dentro de la malla de cálculo, se ha considerado el viento en la propagación de los seas.

6.2 Input

El input del modelo numérico combina la información de la batimetría, la malla de cálculo, corrientes, fricción del fondo, campo de viento, oleaje y condiciones de contorno. Las propagaciones se realizan en modo estacionario, lo que implica que la propagación de la energía en el dominio es instantánea, así como la respuesta del oleaje a variaciones en el campo de viento. Podemos asumir esta simplificación al estar en un dominio de cálculo pequeño y estar propagando un conjunto de casos independientes entre sí.

A continuación, se describen las distintas condiciones de contorno de los casos a propagar. Por un lado, el subconjunto de 500 casos de parámetros agregados, 500 casos de mar de viento y 500 casos para mar de fondo. La propagación se realiza mediante 3 mallas regulares acopladas, de modo que la resolución de la batimetría se vea mejorada en cada una de ellas (downscaling dinámico). La primera malla computacional se define a partir de la batimetría GEBCO de 450 m de resolución, con un $dx - dy$ computacional de 0.01° (1 km aprox.). Las mallas 2 y 3, se definen a partir de la batimetría del USGS de 20 m de resolución, con 0.002° de espaciado de la malla computacional 2 y 0.0005° para la malla 3 (4 subdivisiones en x y en y). Por la extensión del dominio, se emplean coordenadas cartesianas (Figura 12 y Figura 13).

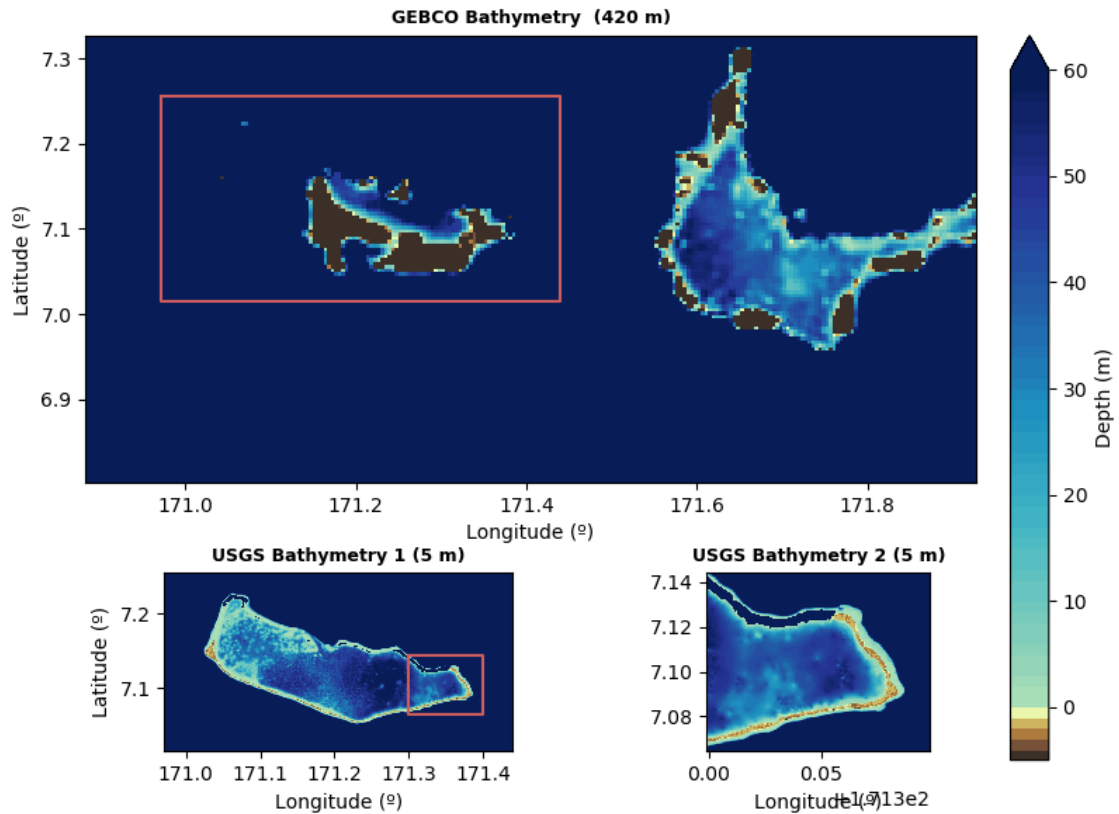


Figura 12. Resolución de las batimetrías de GEBCO y USGS para Majuro




Figura 13. Mallas de cálculo anidadas

El input de la segunda malla se define como el output espectral de la primera simulación a lo largo del contorno de la segunda malla y de la misma forma para la tercera malla centrada en la zona de Delap-Uliga-Djarrit (D.U.D.) donde se concentra la mayoría de la población (15,846 residentes con densidad poblacional de 8506 personas por km^2 (Ford et al., 2018)).

7 ANÁLISIS DE SENSIBILIDAD

Con el fin de conocer la sensibilidad en la propagación del oleaje del periodo de pico (T_p), la dispersión angular (σ), el gamma de Jonswap (γ) y el nivel medio del mar, se propone la propagación de nuevos casos de oleaje variando los parámetros anteriores. Para ello se considera un oleaje inicial de $H_s = 1\text{ m}$, $T_p = 15\text{ s}$ y dirección norte (320°). A partir de este caso inicial, se definen dos posibles variaciones del periodo de pico: 10 y 20 s, dos dispersiones angulares σ : 10 y 15° , dos gammas de Jonswap γ : 1 y 20, y el caso de estar con un nivel de marea de $+0.75$ o de -0.75 m respecto al NMM local. En la Figura 14 se muestran las diferencias en la altura de ola significativa sobre la propagación de los distintos escenarios definidos.

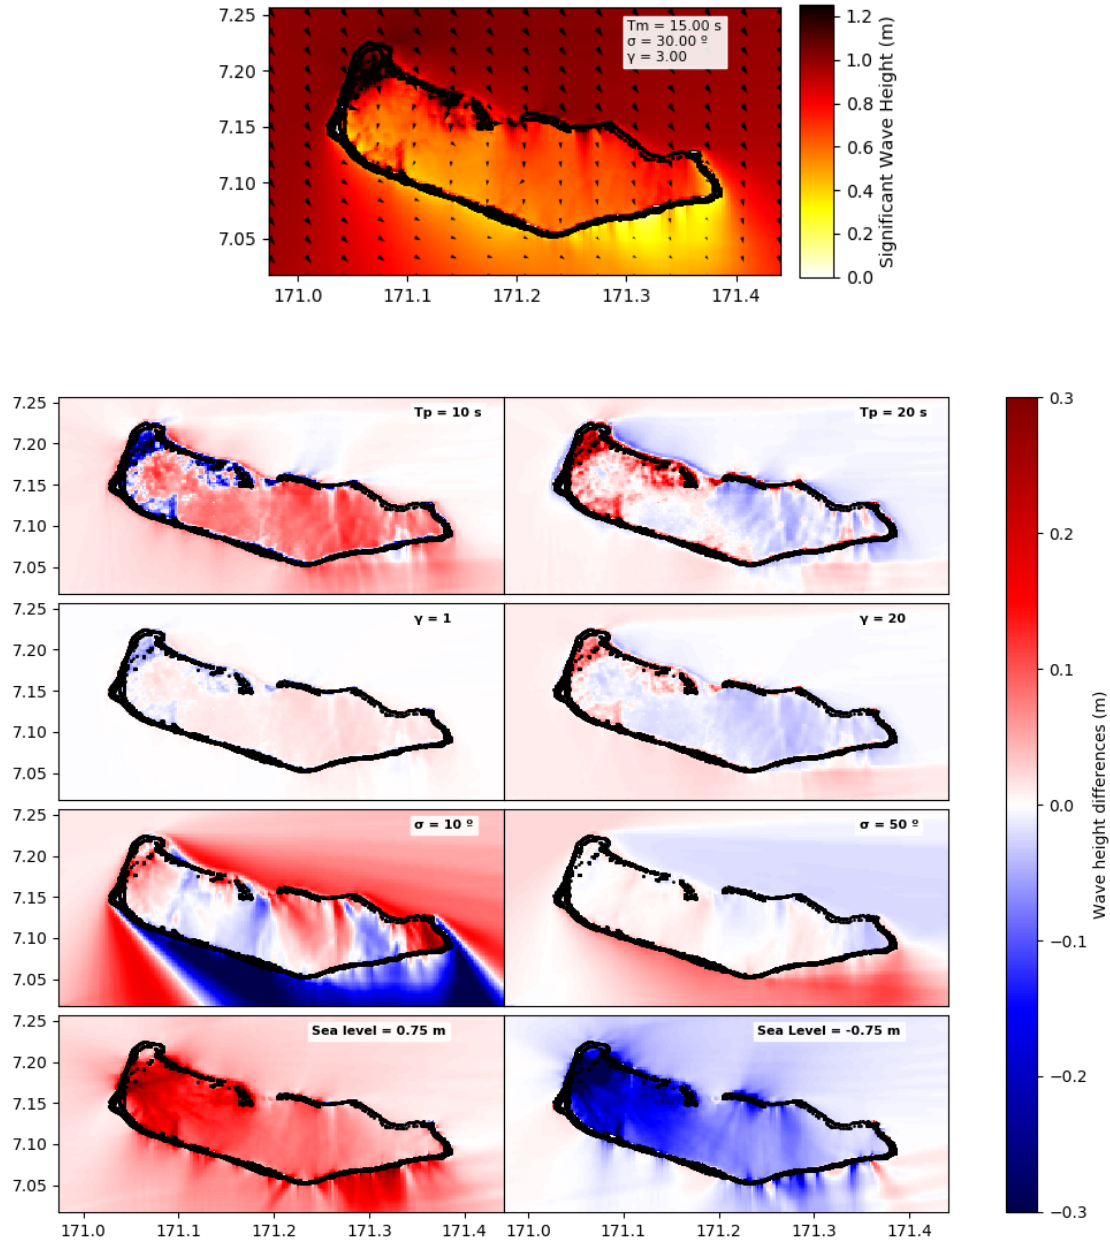


Figura 14. Análisis de sensibilidad de la altura de ola significativa para distintos casos, variando el periodo de pico, gamma de Jonswap, dispersión direccional y nivel medio del mar.

Tradicionalmente en ingeniería de costas se emplean los parámetros de altura de ola significativa H_s , periodo de pico T_p y dirección θ_m para caracterizar el clima marítimo en cualquier punto, asumiendo valores por defecto del factor de pico del espectro y la dispersión direccional. Sin embargo, en la Figura 14 se observan las diferencias en la propagación de un oleaje con dispersión angular de 10° y hacerlo con una de 50° . La dispersión condiciona completamente la forma del espectro, propagando en el primer caso un espectro tipo swell y en el segundo un tipo sea. Al concentrar en menos frecuencias la energía de la propagación, lleva a un aumento de la altura de ola de más de 30 cm.

Lo mismo ocurre cuando el gamma de Jonswap aumenta, aunque las diferencias en la altura de ola no sean tan marcadas. La altura de ola significativa aumenta considerablemente de forma homogénea en todo el atolón cuando se aumenta el nivel del mar 0.75 m. El oleaje se propagará en una profundidad mayor, con mayor celeridad y por tanto mayor energía, sintiendo el fondo más tarde y disipando menos energía.

8 OLEAJE EN LA LAGUNA INTERIOR

La fase de El Niño 2015/2016 fue una de las más fuertes registradas, dejando en Majuro el mínimo nivel del mar desde diciembre de 1997. A pesar del bajo nivel del mar, durante los meses de julio y octubre de 2015 ocurrieron varios eventos de inundación interior del lago debido a fuertes vientos del oeste (Figura 15).

La línea de costa encierra un lago de ~ 37 km de extensión, con profundidades de > 40 m. El periodo de fuertes vientos del oeste soplando de forma persistente generó olas relativamente grandes para una zona generalmente no expuesta al oleaje. Aunque no se tomaron medidas, los que sufrieron el impacto cuentan que eran de más de 2 metros de altura (Ford et al., 2018).



Figura 15. a) Impacto del oleaje en el evento de marzo de 2014 sobre la línea de costa, b) agua acumulada en el norte de Rita durante el evento de marzo de 2014, c) y d) impacto del oleaje de viento sobre estructuras en los eventos de julio y octubre de 2015. Fuente: (Ford et al., 2018)

En este apartado se propone simular los eventos de oleaje producidos por el intenso viento de El Niño 2015/2016. Para ello se compara la altura de ola significativa sobre la zona D.U.D producida por un viento de intensidad 10 m/s y el máximo viento registrado entre julio y octubre 2015 de 25 m/s. En la Figura 16 y Figura 17 se muestra el resultado de la propagación de la altura de ola significativa en la malla 2 para viento de 10 m/s y en la malla 3 para un viento de 25 m/s respectivamente.




Figura 16. Altura de ola significativa en la malla 2 de la propagación del oleaje generado por 10 m/s de viento




Figura 17. Altura de ola significativa en la malla 3 de la propagación del oleaje generado por 25 m/s de viento

El (Shore Protection Manual, 1984) presenta unos gráficos de la altura de ola significativa en indefinidas como función de la velocidad del viento, longitud del fetch y duración del viento. Para un viento de 10 m/s soplando sobre 34 km de forma indefinida, (oleaje totalmente desarrollado) la predicción es de 1 m de altura de ola significativa y 4.5 s de periodo pico. Para un viento de 25 m/s, la altura de ola sería 2.1 m con 6 s de periodo de pico. El modelado numérico de las propagaciones ha permitido confirmar el desarrollo teórico del Shore Protection Manual. En la zona de D.U.P con un viento extremo del oeste de 25 m/s se llega a una altura de ola significativa de más de 2 metros, la misma situación que se vivió en marzo del 2014. El resultado muestra la capacidad del viento para generar oleaje en el interior de la laguna y por tanto la necesidad de considerarlo como otro modo potencial de inundación costera.

9 ALGORÍTMO DE CLASIFICACIÓN DE MÁXIMA DISSIMILITUD (MDA)

El alto coste computacional que supondría propagar el conjunto de casos generados con los 40 años de datos del Superspectro hace necesario emplear herramientas estadísticas que permitan reducir el conjunto de datos a un número de casos representativos para realizar un downscaling híbrido. Se emplea para ello el algoritmo de máxima disimilitud (MDA) definido en el trabajo de (Camus et al., 2011).

Dado un conjunto de datos multidimensionales de tamaño N , $X = \{x_1, \dots, x_N\}$, es posible seleccionar un subconjunto de vectores $M = \{v_1, \dots, v_M\}$ que represente la variabilidad de los datos originales aplicando el algoritmo de clasificación MDA.

La selección se inicia a partir de un vector de la muestra de datos $N \{v_1\}$ y el resto de vectores del subconjunto se seleccionan de forma iterativa buscando los elementos del conjunto de datos más disímiles/distintos. El algoritmo finaliza cuando alcanza las M iteraciones. Para considerar un espacio n -dimensional con los mismos ejes, primero se normalizan las variables, diferenciando entre variables escalares y direccionales. Las disimilitudes entre los puntos se calculan mediante la distancia euclídea y por último se de-normalizan las variables para volver al rango inicial

Normalización de las variables

$$X_i = \{H_s, T_p, \theta_m, \gamma, \sigma\}$$

Las variables escalares se normalizan a valores entre $[0, 1]$ con una transformación lineal simple a partir del máximo y el mínimo de cada variable. Para las variables direccionales (θ_m) en radianes, la máxima diferencia es π y la mínima 0, por lo que los valores se dividen entre π para tener la distancia normalizada entre $[0, 2]$.

$$H_s^{min} = \min(H_s); H_s^{max} = \max(H_s)$$

Distancia EC

$$\|X_i - D_j\|$$

$$= \sqrt{(H_i - H_j^D)^2 + (T_i - T_j^D)^2 + (\min(|\theta_i - \theta_j^D|, 2 - |\theta_i - \theta_j^D|))^2 + (\gamma_i - \gamma_j^D)^2 + (\sigma_i - \sigma_j^D)^2}$$

$$D_j = \{H_j^D, T_j^D, \theta_j^D, \gamma_j^D, \sigma_j^D\} \quad (j = 1, \dots, M)$$

De-normalización de las variables

$$D_j^* = \{H_{s,j}^D, T_{m,j}^D, \theta_m^D, \gamma_j^D, \sigma_j^D\} \quad (j = 1, \dots, M)$$

El MDA se aplicará a 3 conjuntos de datos, por un lado, a los parámetros agregados del espectro y por otro lado a las particiones del espectro, diferenciando los seas y los swells. De esta forma, el mar de viento tendrá dos dimensiones añadidas, la velocidad y la dirección del viento.

En esta metodología, se propone reducir las dimensiones del MDA eliminando la variable de altura de ola significativa H_s para las propagaciones de parámetros agregados y swells, de modo que todos los casos tengan altura igual a 1 metro. La altura propagada será directamente el coeficiente de propagación y serán más fácil observar a simple vista los procesos de transformación del oleaje (refracción y asomeramiento). Finalmente, para conocer la altura real propagada en un punto bastaría con multiplicar la altura de ola original por la altura propagada en el caso de $H_s = 1\text{m}$.

Las variables que definen el MDA para cada conjunto de datos, y que se usarán para la propagación con el modelo numérico SWAN que se describe en el siguiente apartado, son las siguientes:

- | | |
|--------------------------|--|
| (1) Parámetros agregados | T_p, θ_m |
| (2) Mar de viento | $H_s, T_p, \theta_m, \sigma, \gamma, W_{spd}, W_{dir}$ |
| (3) Mar de fondo | $T_p, \theta_m, \sigma, \gamma$ |

En la Figura 18 se muestra la selección de los 500 casos representativos del conjunto de datos de parámetros agregados. La distribución conjunta de T_p y θ_m permite visualizar las direcciones de llegada de swells de largos periodos. La familia de periodos máximos corresponde al sector sur (~ 25 s), con periodos de 20 s de las direcciones del norte y noreste y energía llegando del oeste.




Figura 18. Selección del subconjunto de casos ($N=500$) de puntos representativos T_p, θ_m con el algoritmo del MDA para los parámetros agregados

La selección del subconjunto de casos del MDA para mar de viento y mar de fondo se muestran en la Figura 19 y Figura 20 respectivamente.

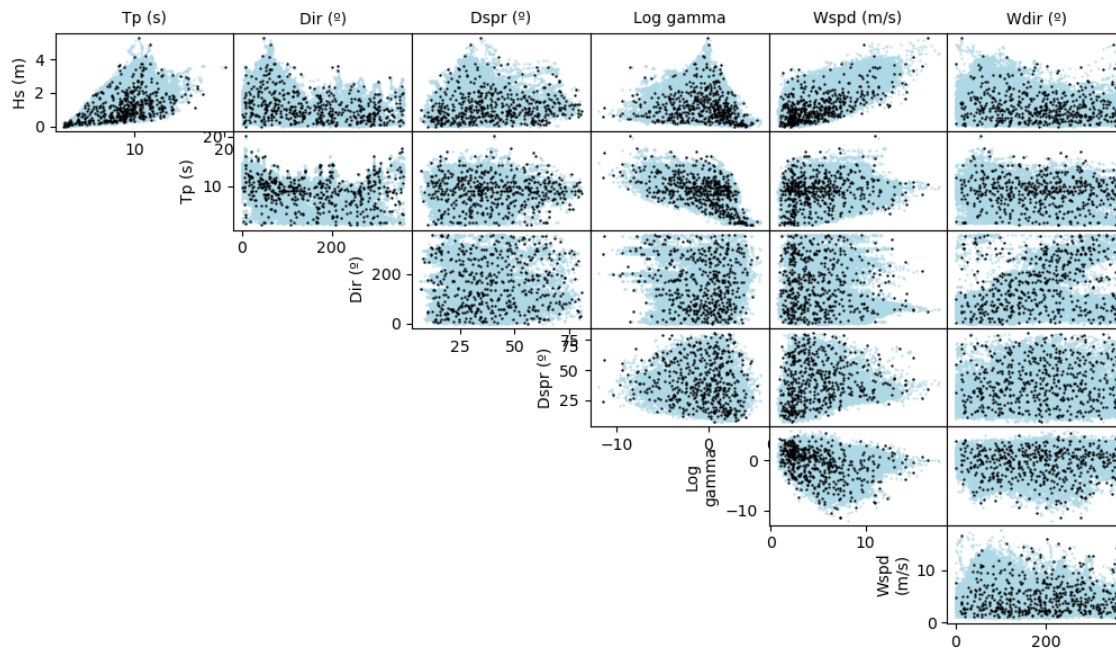


Figura 19. Selección del subconjunto de casos ($N=500$) de puntos representativos $H_s, T_p, \theta_m, \sigma, \gamma$ con el algoritmo de MDA para el de mar de viento




Figura 20. Selección del subconjunto de casos ($N=500$) de puntos representativos $T_p, \theta_m, \sigma, \gamma$ con el algoritmo MDA para el mar de fondo

10 RESULTADOS DE LA PROPAGACIÓN NUMÉRICA

En teoría lineal de oleaje, cuando incide el viento sobre una determinada región durante un periodo de tiempo, se genera un mar de viento que se propaga con la celeridad de grupo $C_g = g/4\pi f$, igual a la distancia recorrida entre el tiempo. El espectro del oleaje sufre una dispersión dada por $f^2 = gk/(2\pi)^2$, donde (f) es la frecuencia, (g) la aceleración de la gravedad y (k) el número de onda. Cuando el oleaje se acerca a la costa y comienza a sentir el fondo, los procesos de transformación de oleaje dejan de ser lineales. Un swell propagándose con 20 s de periodo empieza a sentir la batimetría a 300 m de profundidad en Majuro, lo que se produce muy cerca de la costa al tener una plataforma muy pronunciada. Procesos de transformación como el asomeramiento se dará en los pocos metros de aguas someras, mientras el giro del frente por refracción se podrá ver a mayor escala. A continuación, se muestran los resultados de las propagaciones sobre las mallas anidadas 1, 2 y 3 en orden de resolución creciente del subconjunto de casos de parámetros agregados, mar de viento y mar de fondo respectivamente. Para las simulaciones de los parámetros agregados y el mar de fondo en los que el estado de mar se definía con altura de ola igual a 1 m, la propagación muestra directamente el coeficiente de propagación, siendo mayor que 1 cuando se produce asomeramiento y menor a 1 en las zonas de refracción. La propagación de los primeros 25 casos del MDA de parámetros agregados se muestra en las Figuras 21, 22 y 23 con su coeficiente de propagación, periodo medio y dirección respectivamente. Con la resolución de esta malla 1 (450 m), no se ven zonas de asomeramiento por estar propagando el oleaje en indefinidas, sin embargo, Majuro queda protegido por el atolón de Arno en direcciones de propagación del sector este, lo que se ve en las grandes zonas de refracción.

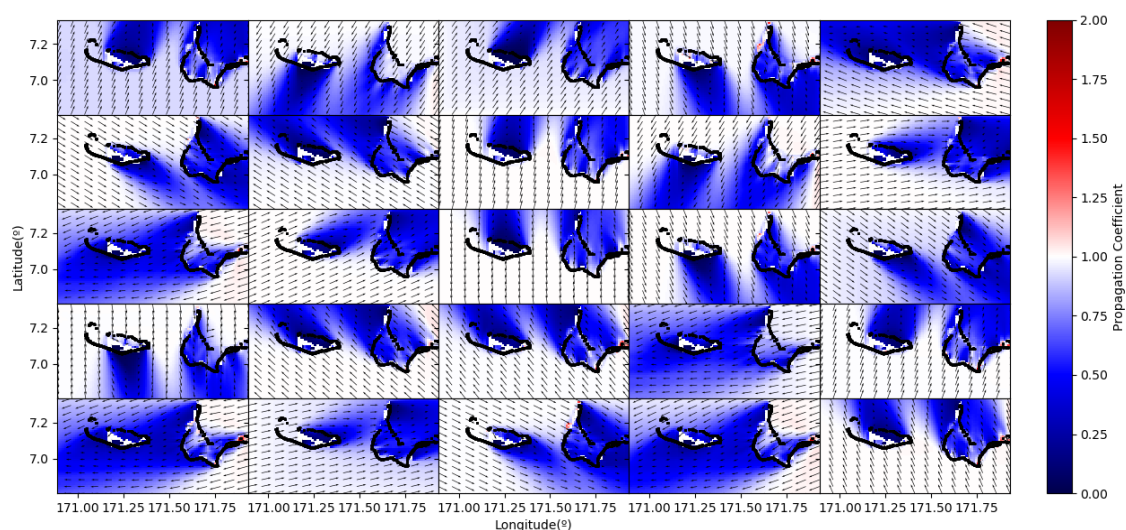


Figura 21. Coeficiente de propagación de los primeros 25 casos del MDA de casos de parámetros agregados (Malla 1)




Figura 22. Periodo medio de los primeros 25 casos del MDA de casos de parámetros agregados (Malla 1)




Figura 23. Dirección de propagación de los primeros 25 casos del MDA de casos de parámetros agregados (Malla 1)

Las Figuras 24, 25 y 26 muestran la altura de ola significativa, periodo medio y dirección de las primeras 25 propagaciones del subconjunto de datos de mar de viento sobre la malla 2 de resolución 200 m.

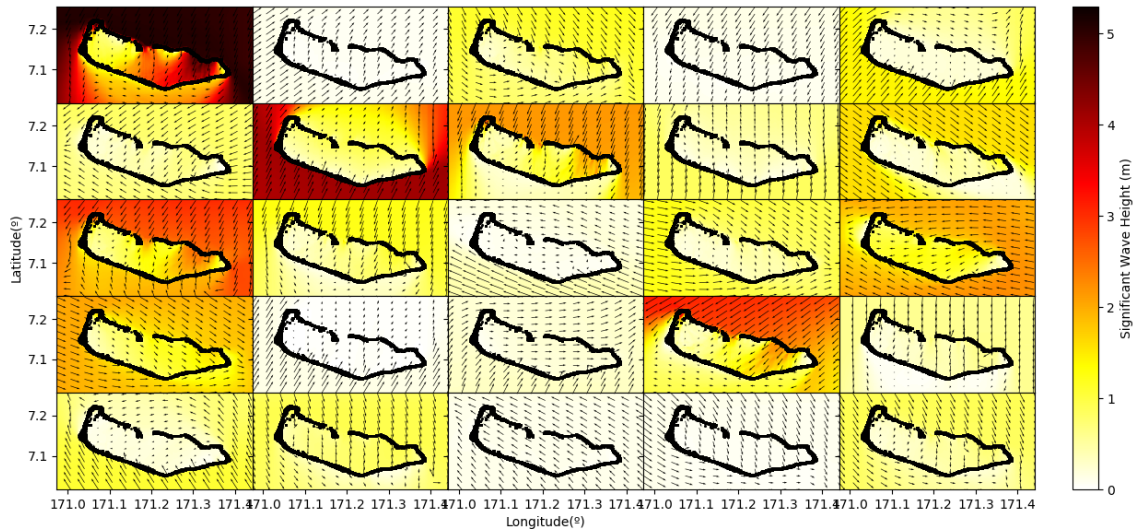


Figura 24. Altura de ola significativa de los primeros 25 casos del MDA de casos de mar de viento (Malla 2)



Figura 25. Periodo medio de los primeros 25 casos del MDA de casos de mar de viento (Malla 2)




Figura 26. Dirección de propagación de los primeros 25 casos del MDA de casos de mar de viento (Malla 2)

Por último, en la Figura 27, 28 y 29 se muestra el coeficiente de propagación de las primeras 25 propagaciones del MDA de mar de fondo sobre la malla 3 de resolución 50 m. La mejora de la resolución permite visualizar los procesos de transformación más detallados.




Figura 27. Coeficiente de propagación de los primeros 25 casos del MDA de casos de mar de fondo (Malla 3)




Figura 28. Periodo medio de los primeros 25 casos del MDA de casos de mar de fondo (Malla 3)




Figura 29. Dirección de propagación de los primeros 25 casos del MDA de casos de mar de fondo (Malla 3)

11 RECONSTRUCCIÓN (RBF)

El algoritmo de clasificación MDA ha permitido reducir el número de casos a propagar. Para conocer la propagación de los restantes casos se usan una técnica de interpolación no lineal basada en funciones de base radial (RBF).

A partir de M puntos dispersos en un espacio de dimensión n $\{x_0, \dots, x_M\}$ y sus valores asociados en una función real $\{f_1, \dots, f_M\}$, es posible obtener la función real $f = f(x)$ mediante la aproximación RBF que permita extrapolar al resto de datos multivariados. La función aproximada tiene la siguiente forma:

$$RBF(x) = p(x) + \sum_{j=1}^M a_j \Phi(\|x - x_j\|)$$

donde Φ es la función de base radial, $\| \cdot \|$ es la norma euclidiana, $p(x)$ es la base monomial $\{p_0, p_1, \dots, p_n\}$, formada por un número de monomios de grado 1 igual al número de dimensiones del dataset (n) y un monomio de grado 0, siendo $b = \{b_0, b_1, \dots, b_n\}$, los coeficientes de esos monomios. Los coeficientes del RBF a_j y los coeficientes de los monomios b , se obtienen aplicando las restricciones de la interpolación.

Los M casos seleccionados con el algoritmo de clasificación MDA forman el subconjunto de casos n dimensionados a propagar con un modelo numérico a costa. La aproximación RBF evalúa la interpolación en cada una de las dimensiones. En este caso, 5 variables definen las características del oleaje, la altura de ola significativa, el periodo de pico, la dirección media, el gamma de Jonswap y la dispersión direccional $D_j^* = \{H_s^D, T_p^D, \theta_m^D, \sigma^D\}$.

Las funciones de interpolación para cada variable diferencian entre variables escalares (H_s^D, T_p^D, σ^D) y variables direccionales (θ_m^D), de modo que las variables escalares se normalizan en una escala de 0 a 1 y las direccionales se dividen entre π y se aplica la distancia circular.

La función de interpolación se define como:

$$RBF(x) = p(x) + \sum_{j=1}^M a_j \Phi(\|x - x_j\|)$$

donde $p(x_i) = b_0 + b_1 H_i + b_2 T_i + b_3 \theta_i + b_4 \gamma_i + b_5 \sigma_i$, Φ es una función Gausiana con parámetro de forma c:

$$\Phi(\|x_i - D_j\|) = \exp\left(-\frac{\|x_i - D_j\|^2}{2c^2}\right)$$

Con el fin de evaluar la calidad de la reconstrucción, se realiza una validación determinista del RBF para los 3 subconjuntos de casos propagados considerando para cada uno de ellos las variables que definen su propagación. De los 500 casos de cada subconjunto, se han reconstruido los 100 últimos, sabiendo a priori su propagación en el punto de la boya. El resultado de la reconstrucción se compara con la propagación para estimar la capacidad del RBF de predecir el resultado sobre nuevos datos. Estos 100 últimos casos son los menos disímiles del MDA, por lo que el error obtenido será el mínimo posible. En la Figura 30 se muestra el scatter entre los valores propagados y reconstruidos de los parámetros agregados, calculando el error medio cuadrático del ajuste como:

$$RMSE = \sqrt{\frac{1}{n_d} \sum_{i=1}^{n_d} (x_i - y_i)^2}$$

La reconstrucción se realiza con los 3 parámetros agregados de H_s, T_p, θ_m .


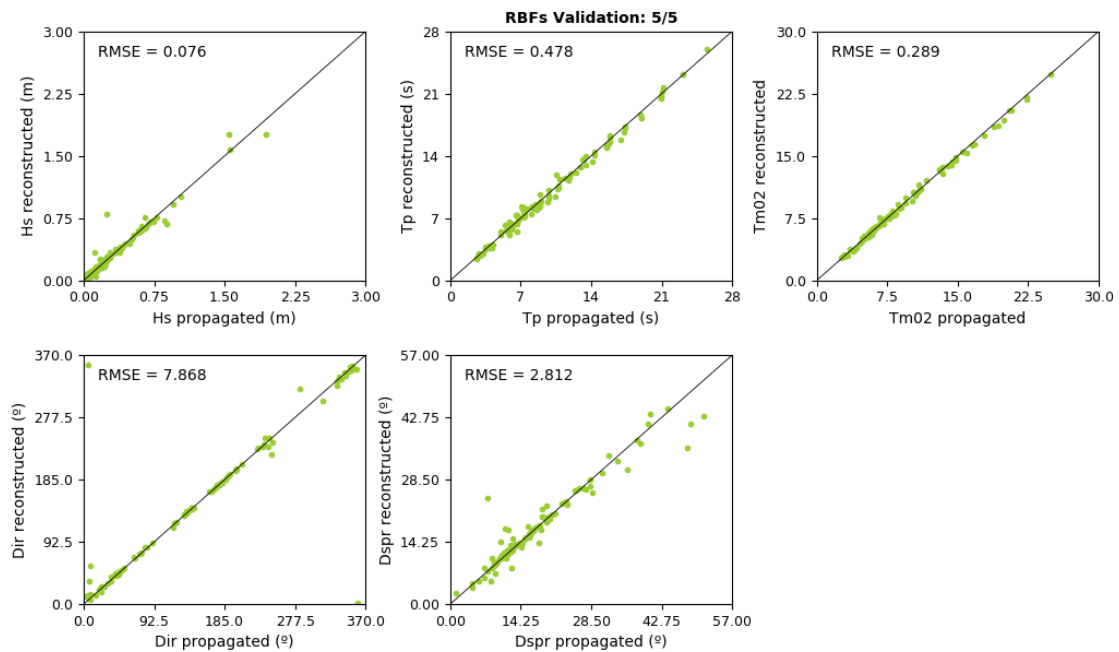



Figura 30. Validación RBF para los parámetros agregados H_s, T_p, θ_m

En la Figura 31 se muestra la validación para los casos de mar de viento. A partir de las variables de $H_s, T_p, \theta_m, \sigma, \gamma, W_{spd}, W_{dir}$ se intenta reconstruir $H_s, T_p, \theta_m, \sigma$ en el punto cercano a la costa. Se ha eliminado el factor gamma de Jonswap de la reconstrucción por no tener un buen ajuste.

Aunque en los seas, este factor tome valores pequeños y similares, para el mar de fondo, el ajuste de γ para periodos de pico y medios similares da valores muy elevados en swells que se generaron a miles de kilómetros. En la Figura 32 se muestra la validación para los casos de mar de fondo.



12 VALIDACIÓN

Los resultados obtenidos con el modelo mediante las particiones del espectro direccional y los parámetros agregados se comparan con datos instrumentales de boya para conocer la calidad y ajuste de los mismos. En la Figura 33 se muestra la serie de altura de ola significativa de la boya frente a la reconstruida por particiones y parámetros agregados en el periodo de junio de 2016 a julio de 2017. Se observa que los parámetros agregados no recogen toda la energía del espectro, dando en general una altura de ola menor a la de la boya. Las series de velocidad de viento y dirección permiten visualizar la respuesta de cada modelo al mismo. Las particiones se encuentran en fase, con una respuesta instantánea a los máximos de viento, pero un ligero desfase respecto a los máximos de altura de la boya.




Figura 33. Serie temporal de altura de ola dada por la boya, por el modelo de parámetros agregados y por las particiones (arriba), velocidad del viento (centro), dirección del viento (abajo)

El ajuste global de todos los puntos reconstruidos y los datos instrumentales de la boya se observa en la el scatter de la Figura 34. El resultado de las particiones tiene dispersión para los máximos de altura de ola, dando en general un muy buen ajuste, Sin embargo, la metodología realizada con parámetros agregados no responde bien a la energía real del espectro y por tanto se pierde energía y la previsión de altura de ola es menor.




Figura 34. Scatter de densidad del parámetro de altura de ola significativa de la boya frente a la H_s propagada de las particiones (izq.) y de los parámetros agregados (der.)

Para valorar la contribución que sobre la energía total tienen las distintas particiones, en la Figura 35 se representa la energía valorada como H_s^2 de las 3 familias de swells procedentes de las direcciones NS (270-30°), ES (30-130°) y SS (130-270°) y del mar de viento.




Figura 35. Comparación de la energía medida en la boya (H_s^2) y la estimada por la metodología propuesta de las particiones. Contribución de la energía de los swells del norte (NS), este (ES), sur (SS) y mar de viento.

Aunque la energía del mar de viento suele predominar sobre el resto de particiones, en la ventana de tiempo seleccionada se observa la importancia en ciertos instantes de las familias de swells del norte y sur. Durante los meses del invierno boreal, los swells del norte predominan frente a los del sur, mientras que, durante los meses de verano, esta tendencia se invierte, cobrando mayor importancia la energía que proviene de las tormentas del hemisferio sur. En la Figura 36 se muestra la misma serie de contribución de energía para un periodo de 2011-01-01 a 2011-03-28.




Figura 36. Reducción de la escala temporal de la Figura 35 de 2011-01-01 a 2011-03-28

El 24 de junio de 2013 la zona sur de Majuro en la que se ubica el Aeropuerto Internacional se inundaba, causando daños severos a la línea de costa (Figura 37). Ese día llegaba energía del sur con poca altura de ola ~ 1.00 m y el viento no era muy energético, sin embargo, periodos de más de 15 s (Figura 38) en un día donde se alcanzaban los máximos de nivel del mar ~ 2.00 m, debido a la fase de La Niña, dañaron las protecciones del aeropuerto depositando arenas, lodos y restos de corales. El registro del nivel del mar (Figura 39) se ha obtenido a partir de los datos del mareógrafo BoM 200832 del National Tidal Centre situado en el interior de la laguna.




Figura 37. Impactos de la inundación el 25 de junio de 2013 a) agua estancada con depósito de sedimentos al sur de Majuro, b) arena, grava y restos de coral depositados al sur de Majuro, c-f) daño en la protección costera con inundación del Aeropuerto Internacional de Majuro. Fuente: (Ford et al., 2018)

A pesar de no contar con datos de la boya, en la Figura se muestra la contribución de las familias de swells modeladas con el método de las particiones en el mes de junio de 2013, donde se aprecia que, durante los 2 días anteriores al evento de inundación, aumentaba la energía de la familia de swells del sur.




Figura 38. Contribución de la energía y periodo de los swells del norte (NS), este (ES), sur (SS) y mar de viento durante el mes de junio de 2013




Figura 39. Nivel medio del mar dado por el mareógrafo BoM 200832 situado en el interior de la laguna

A partir de los parámetros $H_s, T_p, \theta_m, \sigma, \gamma$ de cada partición, se ha reconstruido el espectro direccional teórico del estado de mar del 24 de junio. La reconstrucción se ha realizado de la forma $S(\omega, \theta) = S(\omega) \cdot D(\theta)$, siendo $S(\omega)$ una función de dispersión frecuencial y $D(\theta)$ función de dispersión direccional. Primero se ha realizado el ajuste a un espectro de frecuencia escalar de tipo JONSWAP $S_\eta(f)$ (Hasselmann et al. 1973)

$$S_{\eta\eta}(f, \theta) = S_\eta(f) \cdot D(\theta)$$

Función de dispersión frecuencial JOint North Sea Wave Project 1968 y 1969 (JONSWAP) Hasselmann et al. (1973):

$$S(f) = B_J \cdot H_s^2 \cdot T_p^{-4} \cdot f^{-5} \cdot \exp[-1.25 \cdot (T_p \cdot f)^{-4}] \cdot \gamma^{\exp\left[\frac{-(T_p \cdot f - 1)^2}{2 \cdot \sigma^2}\right]}$$

$$B_J \approx \frac{0.06238}{0.23 + 0.0336 \cdot \gamma - 0.185(1.9 + \gamma)^{-1}} \cdot [1.094 - 0.01915 \cdot \ln(\gamma)]$$

$$\sigma = \begin{cases} 0.07: f \leq f_p \\ 0.09: f > f_p \end{cases}$$

Función de dispersión direccional (Mitsuyasu et al. 1975):

$$D(\theta) = \frac{2^{2s-1}}{\pi} \frac{(s+1)^2}{(2s+1)} \cos\left(\frac{\theta - \theta_m}{2}\right)^{2s}$$

$$s = \frac{2}{\sigma_\theta^2} - 1$$

de modo que:

$$\int_0^{2\pi} D(\theta) d\theta = 1$$

En la Figura 40 se muestra el resultado de ambas reconstrucciones, arriba el espectro direccional modelo de parámetros agregados en el que se asume un $\gamma = 3$ y $\sigma = 15^\circ$, y abajo el espectro direccional resultado de la suma de las propagaciones de los 5 swells y el mar de viento, teniendo en cuenta la dispersión angular y frecuencial propias de cada partición.

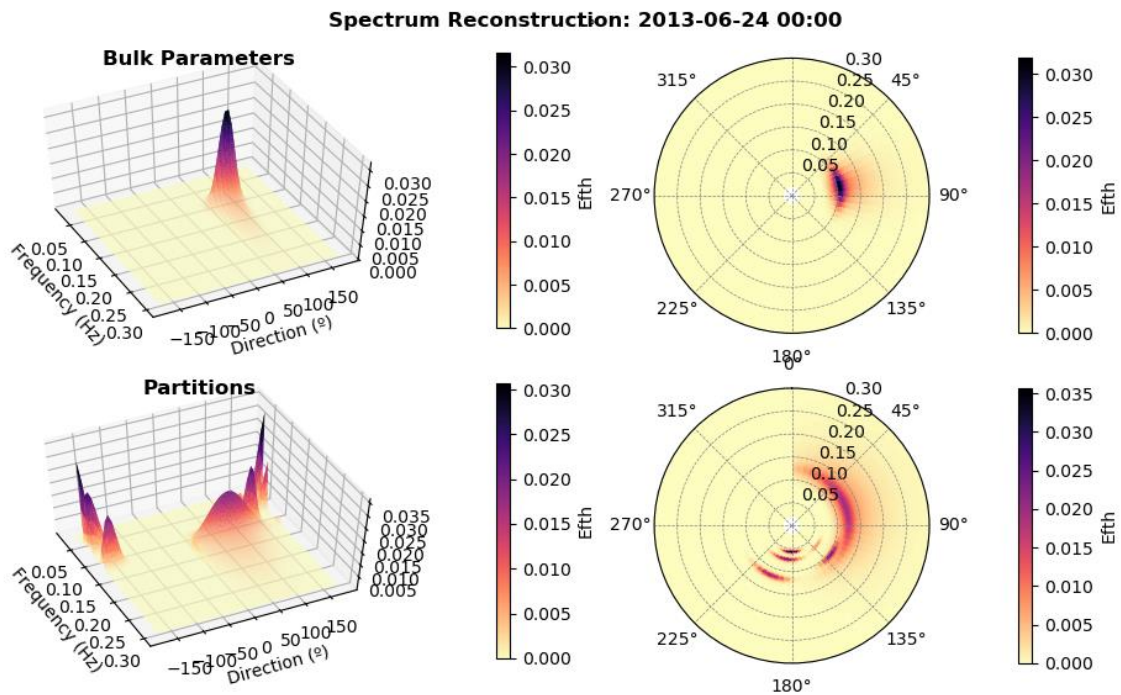


Figura 40. Reconstrucción del espectro direccional completo con la metodología de las particiones y con los parámetros agregados

Las diferencias entre el espectro reconstruido a partir de las particiones y los parámetros agregados muestran claramente por qué ese día no se esperaba que el sur de Majuro quedara inundado. Los parámetros agregados dan un buen resultado para evaluar las condiciones de oleaje más energéticas o medias, sin embargo, pierde la información del espectro y no es capaz de dar una buena previsión frente a inundaciones que resulten de la combinación de estados de mar poco energéticos, pero con potencial de causar inundación

13 ESTUDIO DEL CLIMA MARÍTIMO

El estudio del clima marítimo en aguas profundas definido por un espectro multimodal y su transformación a costa no resulta sencillo. Se plantea analizar el clima marítimo a lo largo de la costa de Majuro a partir de los sistemas de oleaje seleccionados, tanto de mar de viento (predominante del noreste), como de mar de fondo. Para ello se definen 3 posibles familias de llegada de swells en el Pacífico: swells del este con ángulos de (30 – 130°), del sur (130 - 270°) y del norte (270 – 30°) (Figura 41).

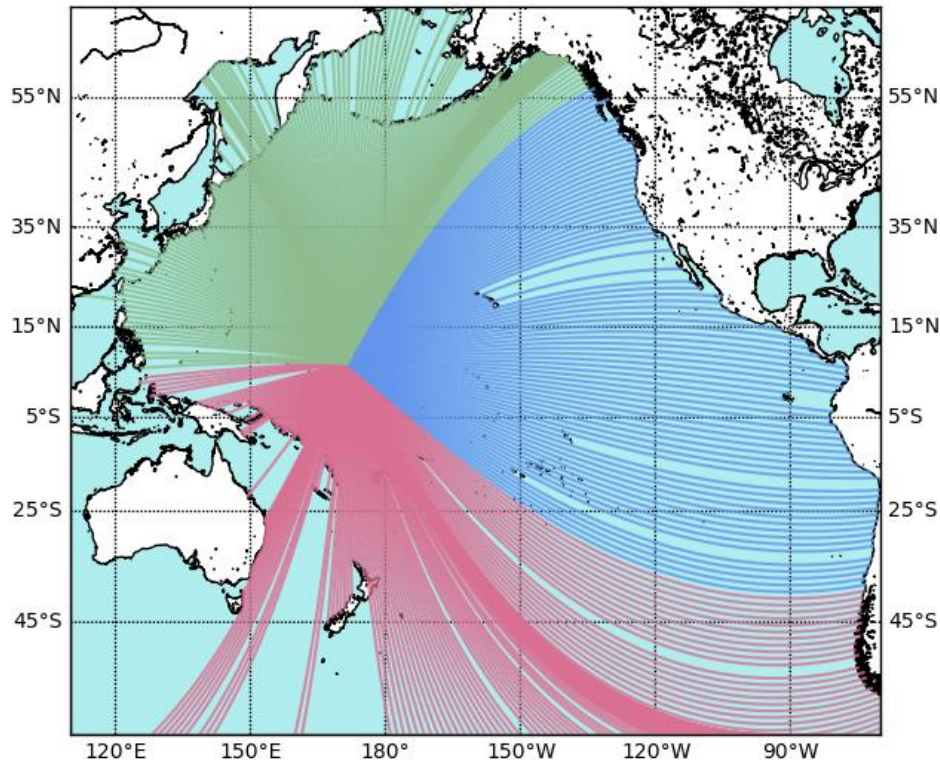


Figura 41. Llegada de swells del Pacífico a Majuro definiendo 3 familias de los sectores [30, 130], [130, 270], [270, 30]” swell fields”

El análisis se realizará a partir de las propagaciones del subconjunto de sea y de swells, considerando que estas propagaciones son las representativas del conjunto de datos de 40 años de oleaje del CSIRO. Los puntos en los que se ha evaluado el output de la propagación se han definido con una profundidad constante igual a 1700 m a lo largo del atolón (Figura 42). En cada punto se ha evaluado el flujo de energía medio, definido como $H_s^2 \cdot T_p$ y se calcula la contribución al flujo total de energía de cada familia de oleaje mediante gráficos de sector circular en la Figura 42 y de forma lineal a lo largo de todo el atolón en la Figura 43. En la zona norte del atolón (O - D) se observa la mayor contribución al flujo de energía de las familias de swells del norte y este, mientras la zona sur del atolón está más afectada por el sector sur de swells




Figura 42. Gráfico circular de la contribución al flujo de energía medio de cada sistema de oleaje




Figura 43. Porcentaje de contribución al flujo de energía medio de cada sistema de oleaje

La metodología aplicada, basada en la teoría lineal, define una propagación espectral lineal de los distintos sistemas de oleaje en la que el espectro propagado es la suma de los espectros individuales propagados. En la Figura 44 se muestra un estado de mar compuesto por 3 swells y en la Figura 45 el mismo estado de mar ya agregado según:

$$H_s = \sqrt{\sum_{i=1}^N H_{si}^2}$$

$$T_m = \sqrt{\frac{\sum_{i=1}^N H_{si}^2}{\sum_{i=1}^N T_{mi}}}$$

$$\theta_m = \text{atan} \left(\frac{\sum_{i=1}^N H_{si}^2 \cdot T_{mi} \cdot \sin \left(\theta_i \cdot \frac{\pi}{180} \right)}{\sum_{i=1}^N H_{si}^2 \cdot T_{mi} \cdot \cos \left(\theta_i \cdot \frac{\pi}{180} \right)} \right)$$




Figura 44. Dirección y altura de ola de 4 familias de oleaje propagas a lo largo del atolón (1 sea y 3 swells)




Figura 45. Dirección, altura de ola significativa y periodo medio agregados de las familias de oleaje definidas en la Figura 44

14 CONCLUSIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN

14.1 Conclusiones

Se ha desarrollado un downscaling híbrido para transferir la información del oleaje de profundidades indefinidas a costa en pequeñas islas. La metodología se basa en la creación de un input basado en la convolución de llegada de los distintos sistemas de swells y sea, selección de M estados de mar representativos del clima marítimo con el algoritmo MDA, propagación dinámica de los casos seleccionados con el modelo numérico SWAN y reconstrucción de las series en punto cercano de la costa con la técnica de interpolación RBF.

La metodología ha sido aplicada en el atolón de Majuro (República de las Islas Marshall), a partir de un input de 40 años de datos basado en las particiones del espectro direccional completo y otro input basado en los parámetros agregados del espectro. Los distintos inputs han sido parametrizados según sus variables representativas: parámetros agregados H_s, T_p, θ_m , sea $H_s, T_p, \theta_m, \sigma, \gamma, W_{spd}, W_{dir}$ y swell $H_s, T_p, \theta_m, \sigma, \gamma$. A partir de las distintas variables involucradas en la propagación, se ha realizado un análisis de sensibilidad del periodo de pico, dispersión angular, gamma de Jonswap y nivel del mar, observando el aumento significativo de la altura de ola propagada cuando aumenta el nivel del mar y se reduce el periodo de pico. Modificando la forma del espectro hacia un espectro tipo swell, disminuyendo la dispersión angular o aumentando el gamma de Jonswap también aumenta la altura de ola al concentrar la energía en menos frecuencias.

Majuro experimenta distintos modos de inundación costera y del interior de la laguna. Con el objetivo de recrear el evento de inundación del 24 de marzo de 2015, se ha simulado la propagación de altura de ola con un viento medio en la región de 10 m/s y el viento máximo alcanzado durante el evento de 25 m/s del oeste. Los resultados confirman la predicción de altura de ola y periodo que muestra el (Shore Protection Manual, 1984) para un fetch de 34 km soplando de forma indefinida sobre profundidades indefinidas, alturas de 1 m y 2.1 m respectivamente.

La validación de las series reconstruidas muestra la capacidad del downscaling híbrido para mejorar el conocimiento del clima marítimo en pequeñas islas. A partir de los datos de una boya al este del atolón se ha podido comparar el resultado de la altura de ola significativa reconstruida mediante particiones del espectro y mediante parámetros agregados. El método de las particiones proporciona un ajuste satisfactorio de la altura de ola significativa, con algo de dispersión para alturas de ola máximas. El método de los parámetros agregados subestima en gran medida la energía incidente. El hecho de parametrizar el espectro direccional en 3 parámetros agregados, supone perder una cantidad significativa de detalles relacionados con la propagación de la energía y su llegada a costa. El 24 de junio de 2013, la zona sur de Majuro se inundaba, arrastrando lodos y dañando las protecciones costeras del aeropuerto. Se ha reconstruido el espectro del día del evento mostrando como 5 swells llegando del sur al mismo tiempo que soplaban vientos del este. La reconstrucción del evento según parámetros agregados tiene una dirección de 76° , completamente condicionada por el mar de viento sin ser capaz de ver la energía del sur. Este evento demuestra la importancia de las particiones en la propagación y caracterización del clima marítimo en estados de mar multimodales.

14.2 Hipótesis y limitaciones

Los resultados muestran un buen ajuste para la metodología aplicada a las particiones. Sin embargo, existe cierta dispersión en la serie reconstruida asociada a varias fuentes de incertidumbre. El input espectral de la serie de 40 años de CSIRO no está calibrada, es el resultado del modelo numérico WW3 sobre ciertos puntos de una red de 7 km de resolución que cubre el parte del Pacífico Occidental y Australia. Calibrar el input mejoraría el resultado que nuestra reconstrucción tiene sobre los datos de la boya.

En las propagaciones existen varias fuentes de error. El modelo numérico Swan, considera la superficie emergida del atolón como celdas con total absorción. Se ha empleado el modelo Swan por la extensión del dominio y por dar buenos resultados en la propagación de oleaje cercana a la costa, sin embargo, en modelos numéricos como WaveWatchIII más empleados en resolución de oleaje de grandes cuencas o el océano, si es posible definir una malla de obstáculos en la dirección x y en y con sus coeficientes de transmisión respectivos que definan correctamente el obstáculo que supone la superficie del atolón para el oleaje. Por otro lado, Swan no tiene en cuenta la reflexión que se produce en la pendiente de la plataforma que rodea el atolón, por lo que hay energía que se refleja en aguas someras y no estamos modelando. Se define el input del viento como la media de la serie medida en los 6 puntos CSIRO y su propagación se supone instantánea como el oleaje (modo estacionario). Con esta característica puede existir un cierto desfase entre el pico del viento de nuestra metodología y el pico de oleaje medido en la boya, aunque sea mínimo por la pequeña extensión del dominio. Por último, se explica cierta incertidumbre por la dificultad del reanálisis CFSR para modelar el viento en zonas cercanas al trópico.

14.3 Futuras líneas de investigación

El trabajo realizado queda limitado a profundidades indefinidas donde se cumple la teoría lineal de oleaje. Un paso más en el estudio del clima marítimo en Majuro sería el estudio de la penetración de los swells en el interior del lago considerando las celdas de absorción, la atenuación de energía ofrecida por el arrecife de coral y la reflexión de la plataforma continental en la propagación del oleaje.

Por otro lado, la calibración del hindcast de CSIRO así como la validación de las particiones mediante datos instrumentales de boya o satélite podría mejorar el resultado de la metodología propuesta.

15 REFERENCIAS

- Booij, N, R. C. Rics, L. H. Holthuisjensen. A third-generation wave model for coastal regions: 1. Modelo description and validation (1999)
- Camus, P., Mendez, F. J., Medina, R., & Co, A. S. (2011). Analysis of clustering and selection algorithms for the study of multivariate wave climate, 58, 453–462. <https://doi.org/10.1016/j.coastaleng.2011.02.003>
- Coastal Engineering Research Center Department of the army. (1984). SHORE PROTECTION MANUAL US, I.
- Ford, M., Merrifield, M. A., Becker, J. M., & Ford, M. (2018). Inundation of a low - lying urban atoll island : Majuro , Marshall Islands. *Natural Hazards*. <https://doi.org/10.1007/s11069-018-3183-5>
- Genz, J., j. Aucan, M. Merrifield, B. Finney, K. Joel, and A. Kelen. 2009. Wave navigation in the Marshall Islands: Comparing indigenous and Western scientific knowledge of the ocean. *Oceanography* 22(2):234-245, doi: 10.5670/oceanog.2009.52
- Hasselmann, K., Barnett T.P., Bows, E., Carlos, H., Cartwright, D.E., Enke, K., Ewing, J.A., Gienapp, H. Hasselmann, D.E., Kruseman, P., Meerburg, A., Müller, P., Olbers, D.J., Richter, K., Dell, W., Walden, H. Measurements of Wind-Wave Growth and Swell Decay during the Joint Nort Sea Wave Project (JONSWAP) 1973
- Hanson, J. L., & Philips, O. M. (2001). Automated Analysis of Ocean Surface Directional Wave Spectra, 277–294.
- Hoeke, R. K., Mcinnes, K. L., Kruger, J. C., Mcnaught, R. J., Hunter, J. R., & Smithers, S. G. (2013). Widespread inundation of Paci fi c islands triggered by. *Global and Planetary Change*, 108, 128–138. <https://doi.org/10.1016/j.gloplacha.2013.06.006>
- Portilla, J (2012). Storm-Source-Locating Algorithm Based on the Dispersive Nature of Ocean Swells., Vol 4 No 1. Pags C22-C36
- Portilla-yandún, J., Cavaleri, L., Ph, G., & Vledder, V. (2015). Ocean Surface Waves Wave spectra partitioning and long term statistical distribution, 96, 148–160. <https://doi.org/10.1016/j.ocemod.2015.06.008>
- Liu, P.L.F. and Losada, I.J. (2002). Wave propagation modeling in Coastal Engineering. *Journal of Hydraulic Research*. IAHR, Vol. 40, No. 3, 229-240.
- Mitsuyasu H., F. Tasai, T. Suhara, S. Mizono, M. Ohkusu, T. Honda and K. Rikiishi (1975). Observations of the directional spectrum of ocean waves using a cloverleaf buoy, *J. Phys. Oceanogr.*, 5, 750-760

16 ANEJO 1. CÓDIGOS EN JUPYTER NOTEBOOK


A continuación, se muestran los códigos de alguno de los apartados de la metodología planteada. El trabajo ha sido desarrollado en el entorno de programación de Python y los resultados han sido exportados para una mejor visualización en un Jupyter Notebook.

On the development of a hybrid spectral wave hindcast for Majuro Atoll (Republic of the Marshall Islands)

Map Location

Stations around Marshall Islands from the ocean wave hindcast CAWCR Wave Hindcast 1979-2010 developed by CSIRO (Commonwealth Scientific and Industrial Research Organisation).

The hindcast used the WaveWatch III v4.08 wave model forced with NCEP CFSR hourly winds and daily sea ice, 1979-2010. The dataset contains spectral wave output at 3683 points, as well as gridded outputs on a global 0.4 degree (24 arcminute) grid, with nested Australian and western Pacific subgrids of 10 and 4 arcminutes resolution.



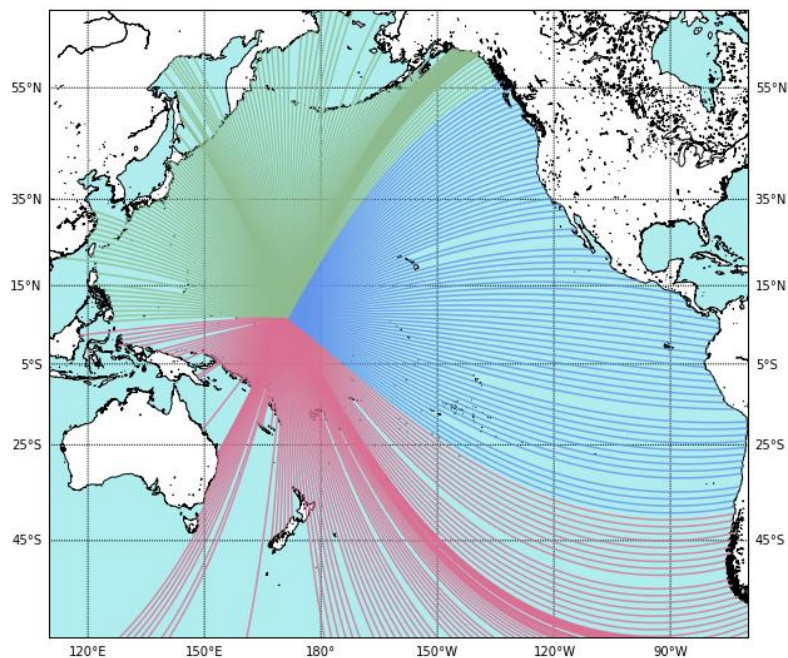
```
In [1]: import os
from os import walk
from os import listdir
import os.path as op
import sys
sys.path.insert(0, op.dirname(os.getcwd()))

import xarray as xr
import numpy as np
import pandas as pd
from scipy.io import loadmat
from scipy import interpolate
import matplotlib.pyplot as plt

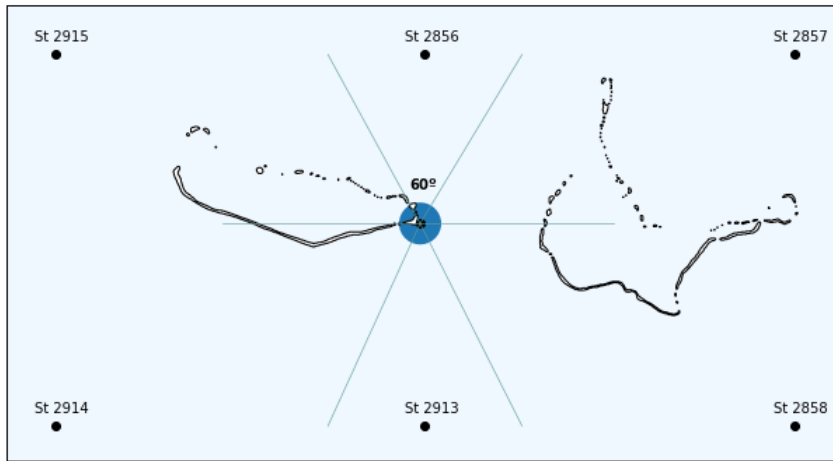
# custom libs
#from lib.wavespectra_lau_func import ws
#from lib.SWP import *
#from lib.MDA import *
from lib.output_swan import plt_prop, find_max
#from lib.plt_Basemap import *

# function
def print_header(string, string2='', nchar=80):
    print('\n{}\n{}:\n{}\n{}'.format(nchar* '=', string, nchar* '=', string2))
```

```
In [4]: plt.figure(figsize=(10,10))
plt_obstructions()
```



```
In [3]: plt.figure(figsize=(11,6))
plt_location()
```



```
In [6]: # File paths
# Input files
p_data = op.join(os.getcwd(), '..', 'data')
p_parameters = op.join(os.getcwd(), '..', 'parameters')
p_shore = op.join(p_data, 'MajuroAtoll')

# Data storage
p_out_txt = op.join(p_data, 'test_Majuro', 'Partitions')
p_out_Swell = op.join(p_out_txt, 'Swells')
p_out_Sea = op.join(p_out_txt, 'Sea')

# Output files: dataset and MaxDiss subset of wave variables (SWAN BCs)
p_dataset_Sw = op.join(p_out_Swell, 'waves_dataset_Sw.pkl')
p_subset_Sw = op.join(p_out_Swell, 'waves_subset_Sw.pkl')
p_subset_sec_Sw = op.join(p_out_Swell, 'subset_sec_Sw.pkl')

p_dataset_Sea = op.join(p_out_Sea, 'waves_dataset_Sea.pkl')
p_subset_Sea = op.join(p_out_Sea, 'waves_subset_Sea.pkl')
p_subset_sec_Sea = op.join(p_out_Sea, 'subset_sec_Sea.pkl')
```

```
In [7]: # Select Dates

inif='1980-01-02T00:00:00.000000000'
finf='1980-02-25T03:00:00.000000000'

# Read spectra from file
data_dir = op.join(os.getcwd(), '..', 'data')
filename = os.path.join(data_dir, "spec.nc")
waves = xr.open_dataset(filename)
dirs = waves.direction.values
for d in range(dirs.shape[0]):
    if dirs[d]>180:
        dirs[d] = dirs[d] - 180
    else:
        dirs[d] = dirs[d] + 180
waves.direction.values=dirs
waves_original = waves.sel(time = slice(inif,finf))
del waves
```

```
In [ ]: # SUPERSPECTRUM
# Define Sectors
st_order=[5,6,3,2,1,4] #Stations and order 2914 2915 2858 2857 2856 2913
Sectors = ([330,30],[30,90],[90,150],[150,210],[210,270],[270,330]) #Sector for each station
ds = SuperSpectrum(waves_original, Sectors,st_order)
waves = ds
del ds

# Add Wind
p_w = os.path.join(data_dir, "Winds_Majuro_stations.mat")
waves_wind = AddMeanWind(waves, p_w, inif, finf)
```

Automated Analysis of Ocean Surface Directional Wave Spectra

Jeffrey L. Hanson Owen M. Phillips

The Johns Hopkins University Applied Physics Laboratory, Laurel, Maryland *The Johns Hopkins University, Baltimore, Maryland*

To facilitate investigations of surface wave processes in the open ocean, a wave spectral partitioning method with automated swell tracking and storm source identification capabilities has been developed. These tools collectively form the Wave Identification and Tracking System (WITS) and have been assembled entirely within the Matlab programming environment. A series of directional wave spectra, with supporting wind observations, is the only required input. Wave spectrum peaks representing specific wind sea and swell wave systems are extracted based on topographic minima, with wind sea peaks identified by wave age criteria. A swell tracking algorithm, combined with linear wave theory, provides a unique approach to storm source identification using the assimilated wave system statistics. The nature of the partitioned spectra allows the continuous, automated identification and tracking of multiple swell generation areas over space and time. Over a 6-day wave record in the Gulf of Alaska, 44 specific swell systems are identified, with up to three systems coexisting at any given time. The presence of atmospheric disturbances on surface weather charts validated the storm source predictions for more than 85% of these systems. The results are synthesized to depict the wave evolution history over the duration of the observations.


```
In [9]: # WAVESPECTRA

wcut = 0.0000001 #Wind cut
msw = 5 #Max number of swells
agef = 1.7 #Age Factor
depths = [8,4399,4270,3125,3760,3703,3797]
depth = np.mean(depths[1:])
depths = np.tile(depth, [len(waves_wind.time),1]); depths=depths[:,0]
depths = xr.DataArray(depths,dims=['time'])
waves_wind['dpt'] = depths
spec_part, ds_part, ds, hs, stats = ws(waves_wind, p_w, inif, finf, wcut, msw, agef)
```

```

=====
Full spectrum:
=====
<xarray.DataArray 'freq' (freq: 29)>
array([[0.035 , 0.0385 , 0.04235 , 0.046585, 0.051244, 0.056368, 0.062005,
        0.068205, 0.075026, 0.082528, 0.090781, 0.099859, 0.109845, 0.12083 ,
        0.132912, 0.146204, 0.160824, 0.176907, 0.194597, 0.214057, 0.235463,
        0.259009, 0.28491 , 0.313401, 0.344741, 0.379215, 0.417136, 0.45885 ,
        0.504735], dtype=float32)
Coordinates:
  * freq      (freq) float32 0.035 0.0385 0.042349998 ... 0.45885003 0.50473505
=====
High-frequency partition:
=====
<xarray.Dataset>
Dimensions:  (dir: 24, freq: 15, latitude: 7, longitude: 7, time: 1300)
Coordinates:
  * time      (time) datetime64[ns] 1980-01-02 ... 1980-02-25T03:00:00
  * dir       (dir) float64 7.5 22.5 37.5 52.5 67.5 ... 307.5 322.5 337.5 352.5
  * longitude (longitude) float32 171.393 170.87 171.4 ... 170.87 171.4 171.93
  * latitude  (latitude) float32 7.089 6.8 6.8 6.8 7.33 7.33 7.33
  * freq      (freq) float32 0.13291247 0.14620373 ... 0.45885003 0.50473505
Data variables:
  efth        (time, freq, dir) float64 0.005762 0.01137 ... 2.692e-05
  wspd        (time) float64 5.914 7.531 7.435 7.122 ... 5.553 8.315 8.127 7.75
  wdir        (time) float64 80.77 80.38 86.52 88.46 ... 64.55 73.09 79.89
  dpt         (time) float64 3.842e+03 3.842e+03 ... 3.842e+03 3.842e+03
=====
Low-frequency partition:
=====
<xarray.Dataset>
Dimensions:  (dir: 24, freq: 14, latitude: 7, longitude: 7, time: 1300)
Coordinates:
  * time      (time) datetime64[ns] 1980-01-02 ... 1980-02-25T03:00:00
  * dir       (dir) float64 7.5 22.5 37.5 52.5 67.5 ... 307.5 322.5 337.5 352.5
  * longitude (longitude) float32 171.393 170.87 171.4 ... 170.87 171.4 171.93
  * latitude  (latitude) float32 7.089 6.8 6.8 6.8 7.33 7.33 7.33
  * freq      (freq) float32 0.035 0.0385 ... 0.10984501 0.120829515
Data variables:
  efth        (time, freq, dir) float64 1.15e-11 2.026e-11 ... 0.001506
  wspd        (time) float64 5.914 7.531 7.435 7.122 ... 5.553 8.315 8.127 7.75
  wdir        (time) float64 80.77 80.38 86.52 88.46 ... 64.55 73.09 79.89
  dpt         (time) float64 3.842e+03 3.842e+03 ... 3.842e+03 3.842e+03
=====
Plotting:
=====


```



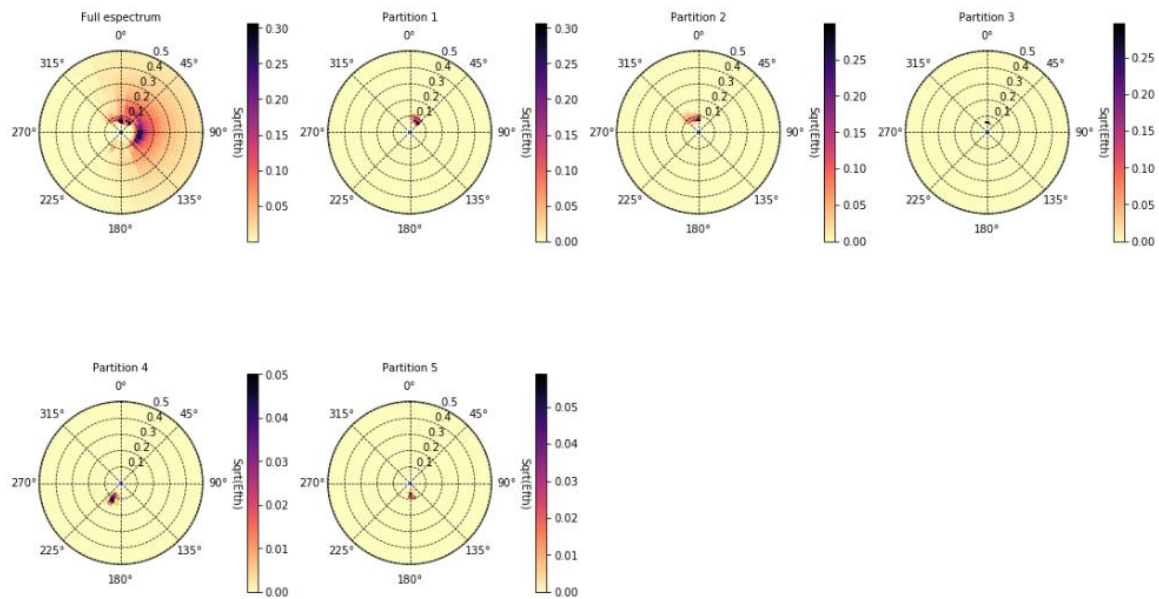
```

In [10]: # PLOT PARTITIONS
PlotPartitions(ds_part) #Partitions over time
time_pos=350

```

```
In [9]: PlotSpectrumPartitions(ds, time_pos, ds_part) #Partitions
```



A hybrid efficient method to downscale wave climate to coastal areas

Paula Camus, Fernando J. Mendez *, Raul Medina

*Environmental Hydraulics Institute IH Cantabria, Universidad de Cantabria, Spain ** Corresponding author at: Environmental Hydraulics Institute, IH Cantabria, Universidad de Cantabria, E.T.S.I. Caminos Canales y Puertos, Avda de los Castros s/n, 39005, Santander, Spain. Tel.: +34 942 201810; fax: +34 942 201860. E-mail address: mendezf@unican.es (F.J. Mendez).

Long-term time series of sea state parameters are required in different coastal engineering applications. In order to obtain wave data at shallow water and due to the scarcity of instrumental data, ocean wave reanalysis databases ought to be downscaled to increase the spatial resolution and simulate the wave transformation process. In this paper, a hybrid downscaling methodology to transfer wave climate to coastal areas has been developed combining a numerical wave model (dynamical downscaling) with mathematical tools (statistical downscaling). A maximum dissimilarity selection algorithm (MDA) is applied in order to obtain a representative subset of sea states in deep water areas. The reduced number of selected cases spans the marine climate variability, guaranteeing that all possible sea states are represented and capturing even the extreme events. These sea states are propagated using a state-of-the-art wave propagation model. The time series of the propagated sea state parameters at a particular location are reconstructed using a non-linear interpolation technique based on radial basis functions (RBFs), providing excellent results in a high dimensional space with scattered data as occurs in the cases selected with MDA. The numerical validation of the results confirms the ability of the developed methodology to reconstruct sea state time series in shallow water at a particular location and to estimate different spatial wave climate parameters with a considerable reduction in the computational effort.

Loading data of the Superspectrum (40 years CSIRO data)

```
In [10]: # Load files
if not os.getcwd() == p_parameters: os.chdir(p_parameters)
ds_part = xr.open_dataset('WS_partitions_MAJURO_specpart_1980_2018.nc')
ds_bulk = np.load('agregated_parameters_SP_Majuro.npz')

# Add winds
inif = ds_part.time[0]
finf = ds_part.time[-1]
p_w = os.path.join(p_parameters, 'Winds_Majuro_stations_1980_2018.mat')
waves_wind = AddMeanWind(ds_part, p_w, inif, finf)

# Separate sea - swell
sea = waves_wind.isel(part = 0) # Partition 0: Sea
swell = waves_wind.isel(part = slice(1, 6)) # Partition 1, 2, 3, 4, 5 Swells

<xarray.Dataset>
Dimensions: (part: 6, time: 341880)
Coordinates:
  * time      (time) datetime64[ns] 1980-01-01 ... 2018-12-31T23:00:00
  * part      (part) int32 0 1 2 3 4 5
    station   int32 ...
Data variables:
  hs          (part, time) float64 ...
  tp          (part, time) float64 ...
  tm02        (part, time) float64 ...
  dpm         (part, time) float64 ...
  dspr        (part, time) float64 ...
  sw          (part, time) float64 ...
```


```
In [11]: # ds_part: time, part
df_bulk = pd.DataFrame({'tp': ds_bulk['Tp'], 'dpm': ds_bulk['Dir'], 'tm02': ds_bulk['Tm02']})
data_bulk = np.array(df_bulk)[:,:]
posnan = np.isnan(data_bulk[:,1])
data = data_bulk[posnan==False, :]

Tp_b = ds_part.tp.values[:]
Dir_b = ds_part.dpm.values[:]
m, n = np.shape(Tp_b)
data1 = np.reshape(Tp_b[:, slice(1, n, 1)], (m*(n-1)))
data2 = np.reshape(Dir_b[:, slice(1, n, 1)], (m*(n-1)))
i = len(data1)
data_p = np.zeros((i, 2))
data_p[:, 0] = data1
data_p[:, 1] = data2
m_per, xedges, yedges = plt_probability(data)
m_per_p, xedges_p, yedges_p = plt_probability(data_p) # Hs, Tp
```

```
In [12]: import matplotlib.pyplot as plt
fig = plt.figure(figsize=[17,11])
ax = plt.subplot(121, projection='polar')
p = ax.pcolormesh(xedges, yedges, m_per, cmap='magma')
ax.set_theta_zero_location('N', offset=0)
ax.set_theta_direction(-1)

ax.set_title('Bulk Parameters', fontsize=10, pad=10)
cbar = plt.colorbar(p, pad=0.15, shrink=0.75, fraction=0.05)
cbar.set_label('Probability Density %', labelpad=-60)

ax1 = plt.subplot(122, projection='polar')
p1 = ax1.pcolormesh(xedges_p, yedges_p, m_per_p, cmap='magma')
ax1.set_theta_zero_location('N', offset=0)
ax1.set_theta_direction(-1)
ax1.set_title('Partitions', fontsize=10, pad=10)
cbar1 = plt.colorbar(p1, pad=0.15, shrink=0.75, fraction=0.05)
cbar1.set_label('Probability Density %', labelpad=-60)
```



Clustering and selection method: MDA

The aim of the selection process is to extract a subset (size M) of wave situations representative of available ocean conditions from the reanalysis database (size N). In the development of computer-based methods to select sets of structurally diverse compounds from chemical databases, dissimilarity-based compound selection has been suggested as an effective method to identify a subset comprising the most dissimilar data in a database (Snarey et al., 1997). The subset selected by the maximum-dissimilarity algorithm (MDA), one subclass of these selection techniques, is distributed fairly evenly across the space with some points selected in the outline of the data space. Therefore, MDA is implemented in the proposed methodology to transfer wave climate from deep water to shallow water.

Given a data sample $X = \{x_1, x_2, \dots, x_N\}$ consisting of N n -dimensional vectors, a subset of M vectors $\{v_1, \dots, v_M\}$ representing the diversity of the data is obtained by applying this algorithm. The selection starts initializing the subset by transferring one vector from the data sample v_1 . The rest of the $M - 1$ elements are selected iteratively, calculating the dissimilarity between each remaining data in the database and the elements of the subset and transferring the most dissimilar one to the subset. The process finishes when the algorithm reaches M iterations.

MaxDiss Classification: BULK PARAMETERS

```
In [12]: p_data = op.join(os.getcwd(), '..', 'parameters')
p_out_txt = op.join(os.getcwd(), '..', 'data', 'test_Majuro')

# Output files: dataset and MaxDiss subset of wave variables (SWAN BCs)
p_dataset_b = op.join(p_out_txt, 'waves_dataset_b.pkl')
p_subset_b = op.join(p_out_txt, 'waves_subset_b.pkl')
p_subset_sec_b = op.join(p_out_txt, 'subset_sec_b.pkl')

if not os.getcwd() == p_data: os.chdir(p_data)
ds_bulk = np.load('agregated_parameters_SP_Majuro.npz')
ds_part = xr.open_dataset('WS_partitions_MAJURO_specpart_1980_2018.nc')

# subset, scalar and directional indexes
ix_scalar = [0] # hs, tp
ix_directional = [1] # dpm

# number of centroids
n_subset = 500 # subset size

df_bulk = pd.DataFrame({'tp': ds_bulk['Tp'], 'dpm': ds_bulk['Dir'], 'tm02': ds_bulk['Tm02']})
data_bulk = np.array(df_bulk)[:,:]
posnan = np.isnan(data_bulk[:,1]) # ¡OJO! Hay valores de hs =
data = data_bulk[posnan==False, :]

# MDA algorithm
out_b = MaxDiss_Simplified_NoThreshold(data, n_subset, ix_scalar, ix_directional)

# To add hs to the centroids
x = []
for i in range(n_subset):
    x.append(find_nearest(data[:,0], out_b[i, 0]))
m_ord = np.zeros([n_subset, 2])
m_ord[:,0] = x
m_ord[:,1] = range(n_subset)
m_ord = m_ord[m_ord[:,1].argsort()] # Sort array with regard to out column
pos = np.int64(m_ord[:,0])

subset_bulk = pd.DataFrame(
    {
        'hs': np.array(ds_bulk['Hs'])[pos],
        'tp': out_b[:,0],
        'dpm': out_b[:,1]
    }
)

print(subset_bulk.info())
```


MaxDiss waves parameters: 341881 --> 500

MDA centroids: 500/500

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 500 entries, 0 to 499
Data columns (total 3 columns):
hs      499 non-null float64
tp      500 non-null float64
dpm     500 non-null float64
dtypes: float64(3)
memory usage: 11.8 KB
None
```

```
In [12]: dataset = df_bulk
import matplotlib.pyplot as plt
fig, (axs) = plt.subplots(1, 1, sharex=True, sharey=True)
axs.scatter(dataset['tp'], dataset['dpm'], marker=".", s = 1, color = 'lightsteelblue')
axs.scatter(subset_bulk['tp'], subset_bulk['dpm'], marker=".", s = 5, color = 'k')
axs.set_ylim(0, 360)
axs.set_title('MDA - Bulk parameters', fontweight='bold')
axs.set_ylabel('Dir (°)')
axs.set_xlabel('Tp (s)')
```

Out[12]: Text(0.5, 0, 'Tp (s)')



MaxDiss Classification: PARTITIONS

MaxDiss Classification: PARTITIONS

```
In [13]: # Load files
if not os.getcwd() == p_data: os.chdir(p_data)
ds_part = xr.open_dataset('WS_partitions_MAJURO_specpart_1980_2018.nc')

# Add winds
inif = ds_part.time[0]
finf = ds_part.time[-1]
p_w = os.path.join(p_data, 'Winds_Majuro_stations_1980_2018.mat')
waves_wind = AddMeanWind(ds_part, p_w, inif, finf)

# Separate sea - swell
sea = waves_wind.isel(part = 0) # Partition 0: Sea
swell = waves_wind.isel(part = slice(1, 6)) # Partition 1, 2, 3, 4, 5 Swells

<xarray.Dataset>
Dimensions: (part: 6, time: 341880)
Coordinates:
  * time      (time) datetime64[ns] 1980-01-01 ... 2018-12-31T23:00:00
  * part      (part) int32 0 1 2 3 4 5
    station   int32 ...
Data variables:
    hs        (part, time) float64 ...
    tp        (part, time) float64 ...
    tm02      (part, time) float64 ...
    dpm       (part, time) float64 ...
    dspr      (part, time) float64 ...
    sw        (part, time) float64 ...
```

WIND SEA

```

In [14]: # subset, scalar and directional indexes
# Data hs, tp, dpm, dspr, gamma, wspd, wdir
ix_scalar = [0, 1, 3, 4, 5] # hs, tp, dspr, gamma, wspd
ix_directional = [2, 6] # dpm, wdir

# number of centroids
n_subset = 500 # subset size
n_partitions = 1 # sea partition 0

data = np.zeros((len(waves_wind.time), 7))
data[:,0] = sea.hs.values
data[:,1] = sea.tp.values
data[:,2] = sea.tm02.values
data[:,3] = sea.dpm.values
data[:,4] = sea.dspr.values
data[:,5] = sea.wspd.values
data[:,6] = sea.wdir.values

data = eliminate_nans(data)

# Calculate gamma JONSWAP
a = 1.411
b = -0.07972
gamma = np.exp((np.log(data[:,1]/(a*data[:,2])))/b)

df_ssi = pd.DataFrame({'hs': data[:,0],
                       'tp': data[:,1],
                       'dpm': data[:,3],
                       'dspr': data[:,4],
                       'gamma': np.log(gamma),
                       'wspd': data[:,5],
                       'wdir': data[:,6]})

data = np.array(df_ssi)[:,:]

# MDA algorithm
out = MaxDiss_Simplified_NoThreshold(data, n_subset, ix_scalar, ix_directional)

subset = pd.DataFrame(
    {
        'hs': out[:,0],
        'tp': out[:,1],
        'dpm': out[:,2],
        'dspr': out[:,3],
        'gamma': np.exp(out[:,4]),
        'wspd': out[:,5],
        'wdir': out[:,6]
    }
)
print(subset.info())

```

MDA centroids: 500/500

```

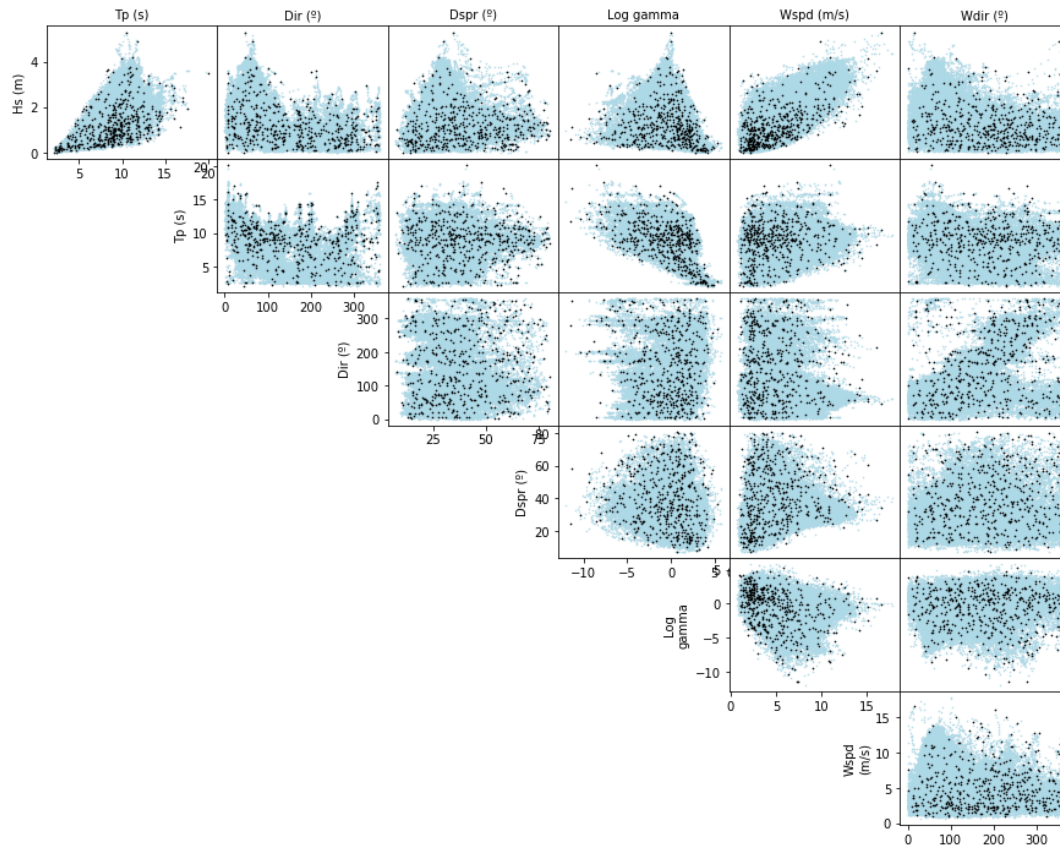
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 500 entries, 0 to 499
Data columns (total 7 columns):
hs      500 non-null float64
tp      500 non-null float64
dpm     500 non-null float64
dspr    500 non-null float64
gamma   500 non-null float64
wspd    500 non-null float64
wdir    500 non-null float64
dtypes: float64(7)
memory usage: 27.4 KB
None

```

```

In [15]: # Scatter
dataset = df_ssi
import matplotlib.pyplot as plt
fig, (axs) = plt.subplots(6, 6, figsize=(15, 12))
plt.subplots_adjust(hspace=0, wspace=0)
scatter_SeaP(axs, dataset, subset)

```

```
In [14]: # SWELL
# subset, scalar and directional indexes
# Data tp, dpm, dspr, gamma
ix_scalar = [0, 2, 3] # tp, dspr, gamma
ix_directional = [1] # dpm

# number of centroids
n_subset = 500 # subset size
n_partitions = 5 # sea partition 0

size = len(swell.time)*n_partitions
data = np.zeros((size, 5))
data[:,0] = np.reshape(swell.hs.values, (size))
data[:,1] = np.reshape(swell.tp.values, (size))
data[:,2] = np.reshape(swell.tm02.values, (size))
data[:,3] = np.reshape(swell.dpm.values, (size))
data[:,4] = np.reshape(swell.dspr.values, (size))

# Avoid dspr == 0
dspr_s = np.copy(data[:,4])
for s in range(len(dspr_s)):
    if data[:,4][s] < 0:
        dspr_s[s] = 1
data[:,4] = dspr_s
data = eliminate_nans(data)

# Calculate gamma JONSWAP
a = 1.411
b = -0.07972
gamma = np.exp((np.log(data[:,1]/(a*data[:,2])))/b)

df_ssi = pd.DataFrame({'tp': data[:,1],
                       'dpm': data[:,3],
                       'dspr': data[:,4],
                       'gamma': np.log(gamma)})

data_mda = np.array(df_ssi[:, :])

# MDA algorithm
out = MaxDiss_Simplified_NoThreshold(data_mda, n_subset, ix_scalar, ix_directional)

# To add hs to the centroids
x = []
for i in range(n_subset):
    x.append(find_nearest(data[:,3], out[i, 1]))
m_ord = np.zeros([n_subset, 2])
m_ord[:,0] = x
m_ord[:,1] = range(n_subset)
m_ord = m_ord[m_ord[:,1].argsort()] # Sort array with regard to out column
pos = np.int64(m_ord[:,0])


subset = pd.DataFrame(
    {
        'hs': np.array(data[:,0][pos]),
        'tp': out[:,0],
        'dpm': out[:,1],
        'dspr': out[:,2],
        'gamma': np.exp(out[:,3])
    }
)
print(subset.info())
```

MaxDiss waves parameters: 1652024 --> 500

MDA centroids: 500/500

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 500 entries, 0 to 499
Data columns (total 5 columns):
hs      500 non-null float64
tp      500 non-null float64
dpm      500 non-null float64
dspr     500 non-null float64
gamma    500 non-null float64
dtypes: float64(5)
memory usage: 19.6 KB
None
```

```
In [15]: # Scatter
dataset = df_ssi
import matplotlib.pyplot as plt
fig, (axs) = plt.subplots(3, 3, figsize=(15, 12))
plt.subplots_adjust(hspace=0, wspace=0)
scatter_SwellP(axs, dataset, subset)
```



Dynamical Downscaling

Deep to shallow water Wave Transformation

In deep water, wind waves are not affected by the bathymetry. However, in their propagation to the coast, waves are transformed due to the interaction with the bathymetry, inducing variations in the significant wave height and in the mean wave direction. The most important transformation processes are refraction and shoaling by bathymetry or current, diffraction around abrupt bathymetric features and energy loss through dissipation near the bottom. Besides, part of wave energy is reflected back to the deep sea. Continuing their shoreward propagation at a shallower water, the wave profile becomes steeper with increasing wave amplitude and decreasing wavelength, the front face of the wave moves at a slower speed than the wave crest causing the overturning motion of the wave crest. The turbulence associated with breaking waves produces great amounts of energy dissipation.

Wave propagation models simulate the wave transformation processes in their propagation to the coast. There are different wave models depending on the mathematical equations implemented in order to describe wave propagation from deep to shallow waters, which suppose different limitations in the processes they are able to model. Therefore, none of the existing models considers all involved physical processes.

Two basic kinds of numerical wave models can be distinguished: phase-resolving models, which are based on vertically integrated, time-dependent mass and momentum balance equations, and phase-averaged models, which are based on a spectral energy balance equation. The application of phase-resolving models, which require 10–100 time steps for each wave period, is still limited to relatively small areas, $O(1-10 \text{ km})$, while phase averaged models can be applied in much larger regions (Losada and Liu, 2002).

The wave energy model SWAN (Booij et al., 1999) with Cartesian coordinates is used due to the size of the propagation domain. The bathymetry of the study area has been obtained from the global mesh GEBCO (General Bathymetric Chart of the Oceans), a mesh with global coverage in a grid of 15 arcseconds of resolution. The 450 m resolution of the mesh is not capable of including the processes of wave transformation, so a second bathymetry of higher resolution is nested for this area. This second bathymetry has been obtained from the digital model of topo-bathymetric elevation of 5 m of resolution developed by the USGS (United States Geological Survey). Furthermore, one of the requirements of the proposed methodology is the assumption of stationary propagations so that the subset of the selected propagation cases can be considered independent.

```
In [18]: # -----
# SWAN subset stationary cases execution
sw.RunCases_Project()
```

Bulk Parameters Methodology

Propagation coefficient and direction map of the general grid (1 km resolution)

```

In [16]: # Load input files
p_dat = op.join(os.getcwd(), 'F:', '\Majuro', 'data', 'test_Majuro_anidado')
p_data = op.join(p_dat, 'Bulk', 'M1_Bulk', '01_stat', 'cases')
p_shore = op.abspath(op.join(p_dat, '..', 'MajuroAtoll'))
p_subset = op.join(p_dat, '..', 'test_Majuro', 'waves_subset_b.pkl')

waves = pd.read_pickle(p_subset)

# Majuro Lon Lat
lon1, lon2 = 170.8829, 171.9271
lat1, lat2 = 6.8021, 7.327
a = 53 # number mesh x
b = 105 # number mesh y
z = np.load(op.join(p_shore, 'shore.npy'))
zz = z[(z[:,0] >= lon1) & (z[:,0] <= lon2)]
zz = zz[(zz[:,1] >= lat1) & (zz[:,1] <= lat2)]

# Plt Quiver Hs - Dir
fig, (axs) = plt.subplots(nrows=5, ncols=5, sharex=True, sharey=True, figsize=(13, 10), constrained_layout=False)
fig.subplots_adjust(wspace=0, hspace=0)
r = 0
c = 0
path, ficheros, archivos = next(walk(p_data))
maxHs, maxTp, maxTm = find_max(p_data, ficheros, 'output.mat')

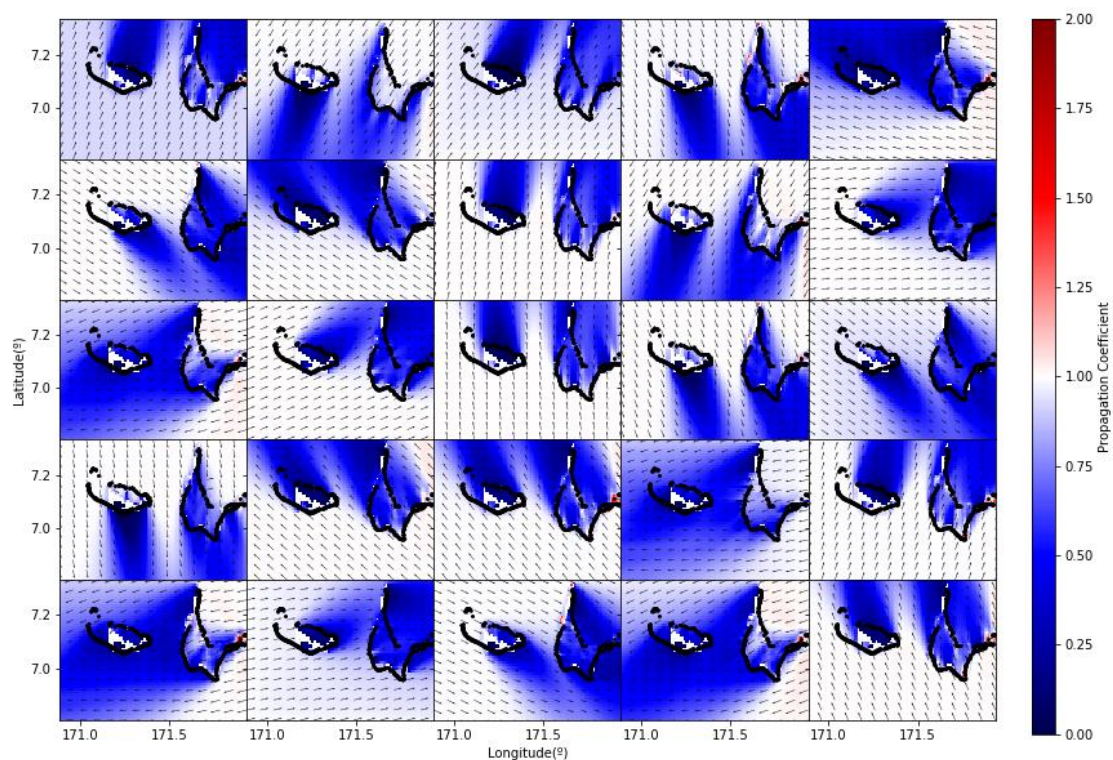
for i in range(25):
    f = ficheros[i] # For each subfolder (cases)
    X, Y, Dir, Hsig, TPsmoo, Xnew, Ynew, u, v = plt_prop(p_data, zz, f, 'output.mat', lon1, lon2, lat1, lat2, a, b)
    ocean = plt.get_cmap('seismic')

    # Plotting output maps Hs Dir
    im = axs[r, c].pcolormesh(X, Y, Hsig, cmap=ocean, vmin=0, vmax=2)
    axs[r, c].quiver(Xnew, Ynew, u, v, width=0.003, scale_units='inches')
    axs[r, c].plot(zz[:,0], zz[:,1], '.k', markersize=2) # Majuro shore

    if c == 4:
        r+=1
        c=0
    else:
        c+=1

cbar_ax = fig.add_axes([0.93, 0.11, 0.02, 0.77])
fig.colorbar(im, cax=cbar_ax)
cbar_ax.set_ylabel('Propagation Coefficient')
axs[4, 2].set_xlabel('Longitude(°)')
axs[2, 0].set_ylabel('Latitude(°)')

```



Partitioning Methodology

WIND SEA

Significant wave height and direction map of the nested grid (200 m resolution)

Partitioning Methodology

WIND SEA

Significant wave height and direction map of the nested grid (200 m resolution)

```
In [17]: # Load input files
p_dat = op.join(os.getcwd(), 'F:', '\Majuro', 'data', 'test_Majuro_anidado')
p_data = op.join(p_dat, 'Partitions', 'Sea', '02_stat', 'cases')
p_shore = op.abspath(op.join(p_dat, '..', 'MajuroAtoll'))
p_subset = op.join(p_dat, '..', 'test_Majuro', 'Partitions', 'Sea', 'waves_subset_Sea.pkl')

waves = pd.read_pickle(p_subset)

# Majuro Lon Lat
lon1, lon2 = 170.973, 171.44
lat1, lat2 = 7.0164, 7.2553
a = 119 # number mesh x
b = 233 # number mesh y

z = np.loadtxt(op.join(p_shore, 'shore_usgs01.dat'))
zz = z[(z[:,0] >= lon1) & (z[:,0] <= lon2)]
zz = zz[(zz[:,1] >= lat1) & (zz[:,1] <= lat2)]

# Plt Quiver Hs - Dir
fig, (axs) = plt.subplots(nrows=5, ncols=5, sharex=True, sharey=True, figsize=(13, 10), constrained_layout=False)
fig.subplots_adjust(wspace=0, hspace=0)
r = 0
c = 0


path, ficheros, archivos = next(walk(p_data))
maxHs, maxTp, maxTm = find_max(p_data, ficheros, 'output.mat')

for i in range(25):
    f = ficheros[i] # For each subfolder (cases)
    X, Y, Dir, Hsig, TPsmoo, Xnew, Ynew, u, v = plt_prop(p_data, zz, f, 'output.mat', lon1, lon2, lat1, lat2, a, b)
    ocean = plt.get_cmap('hot_r')

    # Plotting output maps Hs Dir
    im = axs[r, c].pcolormesh(X, Y, Hsig, cmap=ocean, vmin=0, vmax=maxHs)
    axs[r, c].quiver(Xnew, Ynew, u, v, width=0.003, scale_units='inches')
    axs[r, c].plot(zz[:,0], zz[:,1], '.k', markersize=2) # Majuro shore

    if c == 4:
        r += 1
        c = 0
    else:
        c += 1

cbar_ax = fig.add_axes([0.93, 0.11, 0.02, 0.77])
fig.colorbar(im, cax=cbar_ax)
cbar_ax.set_ylabel('Significant Wave height (m)')
axs[4, 2].set_xlabel('Longitude(°)')
axs[2, 0].set_ylabel('Latitude(°)')
```



SWELL STATES

Propagation coefficient and direction map of the nested grid (50 m resolution)

SWELL STATES

Propagation coefficient and direction map of the nested grid (50 m resolution)

```
In [2]: # Load input files
p_dat = op.join(os.getcwd(), 'F:', '\Majuro', 'data', 'test_Majuro_anidado')
p_data = op.join(p_dat, 'Partitions', 'Swell', '02_stat', 'cases')
p_shore = op.abspath(op.join(p_data, '..', 'MajuroAtoll'))
p_subset = op.join(p_dat, '..', 'test_Majuro', 'Partitions', 'Swell', 'waves_subset_Sw.pkl')
waves = pd.read_pickle(p_subset)

# Majuro Lon Lat
lon1, lon2 = 171.299, 171.399
lat1, lat2 = 7.0644, 7.1444
a = 161 # number mesh x
b = 201 # number mesh y
z = np.loadtxt(op.join(p_shore, 'shore_usgs01.dat'))
zz = z[(z[:,0] >= lon1) & (z[:,0] <= lon2)]
zz = zz[(zz[:,1] >= lat1) & (zz[:,1] <= lat2)]

# Plt Quiver Hs - Dir
fig, (axs) = plt.subplots(nrows=5, ncols=5, sharex=True, sharey=True, figsize=(13, 10), constrained_layout=False)
fig.subplots_adjust(wspace=0, hspace=0)
r = 0
c = 0
path, ficheros, archivos = next(walk(p_data))
maxHs, maxTp, maxTm = find_max(p_data, ficheros, 'output_det.mat')

for i in np.arange(50, 75, 1):
    f = ficheros[i] # For each subfolder (cases)
    X, Y, Dir, Hsig, TPsmoo, Xnew, Ynew, u, v = plt_prop(p_data, zz, f, 'output_det.mat', lon1, lon2, lat1, lat2, a, b)
    ocean = plt.get_cmap('seismic')

    # Plotting output maps Hs Dir
    im = axs[r, c].pcolormesh(X, Y, Hsig, cmap=ocean, vmin=0, vmax=2)
    axs[r, c].quiver(Xnew, Ynew, u, v, width=0.003, scale_units='inches')
    axs[r, c].plot(zz[:,0], zz[:,1], '.k', markersize=2) # Majuro shore

    if c == 4:
        r += 1
        c = 0
    else:
        c += 1

cbar_ax = fig.add_axes([0.93, 0.11, 0.97, 0.77])
fig.colorbar(im, cax=cbar_ax)
cbar_ax.set_ylabel('Propagation Coefficient')
axs[4, 2].set_xlabel('Longitude(°)')
axs[2, 0].set_ylabel('Latitude(°)')

Out[2]: Text(0, 0.5, 'Latitude(°)')
```

